

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Borjan Ranilović

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentori:

Prof. dr. sc. Ivanka Boras, dipl. ing.
Doc. dr. sc. Monika Zovko, dipl. ing.

Student:

Borjan Ranilović

Zagreb, 2017.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se profesoricama Ivanki Boras i Moniki Zovko na mentorstvu prilikom izrade ovog rada. Također se zahvaljujem profesoru Srećku Švaiću na vodstvu i pomoći u izradi i provedbi ovoga rada, te asistentu Ivanu Horvatu i kolegici Josipi Mikulić na njihovom radu na provedbi mjerenja. Zahvaljujem i Institutu za poljoprivredu i turizam u Poreču na njihovom sudjelovanju.

Posebno zahvaljujem svojoj obitelji na njihovoj podršci, savjetima i razumijevanju.

Borjan Ranilović



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
procesno-energetski, konstrukcijski, brodstrojarski i inženjersko modeliranje i računalne simulacije

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur. broj:	

DIPLOMSKI ZADATAK

Student: **Borjan Ranilović** Mat. br. 0035186484

Naslov rada na hrvatskom jeziku: **Primjena infracrvene termografije u određivanju vodnog stresa povrća**

Naslov rada na engleskom jeziku: **Application of infrared thermography for determination water stress in vegetables**

Opis zadatka:

Praćenje ponašanja biljke i pouzdano određivanje potrebe za njezinim navodnjavanjem ekonomski je, agronomski i inženjerski izazov i predmet je istraživanja koja se temelje na mjerenju brojnih parametara. Između ostalih: temperature lista, temperature i vlažnosti tla te temperature i vlažnosti zraka. Nedostatak vode uzrokuje pojavu vodnog stresa kada biljka reagira povišenjem temperature lista i promjenom svog metabolizma.

U radu je potrebno provesti istraživanje ponašanja odabranih vrsta povrća (presadnice rajčice i paprike) koje će obuhvatiti mjerenja i analizu bitnih parametara sa svrhom:

- utvrđivanja u koliko mjeri vodni stres (nedostatak vode) utječe na temperaturu lista presadnica,
- utvrditi učinak vodnog stresa na stopu fotosinteze (zatvaranje puči i zaustavljanje fotosinteze na neko vrijeme) što neposredno može imati negativan utjecaj na prinose i na kakvoću uroda,
- provjeriti mogućnost primjene termografskih mjerenja za određivanje provodljivosti puči,
- provjeriti utjecaj primjene mikorize u uzgoju presadnica na razinu vodnog stresa.

Mjerenja će se provoditi na *Fakultetu strojarstva i brodogradnje* i na *Agronomskom fakultetu Sveučilišta u Zagrebu* u *Zavodu za melioracije*, u kontroliranim uvjetima na odabranim presadnicama u četiri repeticije.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

11. svibnja 2017.

Rok predaje rada:

13. srpnja 2017.

Predviđeni datum obrane:

19., 20. i 21. srpnja 2017.

Zadatak zadao:

Prof.dr.sc. Ivanka Boras

I. Boras

Doc.dr.sc. Monika Zovko

M. Zovko

Agronomski fakultet

Predsjednica Povjerenstva:

Tanja Jurčević Lulić
Prof. dr. sc. Tanja Jurčević Lulić

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	V
POPIS OZNAKA	VI
SAŽETAK.....	VIII
SUMMARY	IX
1. UVOD.....	1
1.1. Osnove termografskog mjerenja	3
2. PREGLED RANIJIH ISTRAŽIVANJA	7
2.1. Procjena vodnog potencijala lista infracrvenim snimanjem i prostornom analizom ...	7
2.1.1. Uvod.....	7
2.1.2. Uvod.....	8
2.1.3. Obrada podataka i rezultati	9
2.2. Istraživanje varijabli u korištenju termografskog snimanja za otkrivanje reakcije na vodni stres kod vinove loze u različitim režimima navodnjavanja.....	11
2.2.1. Uvod.....	11
2.2.2. Mjerenja	12
2.2.3. Obrada podataka i rezultati	13
2.3. Ocjenjivanje različitih pristupa za procjenu i bilježenje vodnog statusa usjeva pamuka infracrvenom termografijom	16
2.3.1. Uvod.....	16
2.3.2. Mjerenja	17
2.3.3. Obrada podataka i rezultati	18
2.4. Bilježenje vodnog stresa usjeva za lokacijski upravljano navodnjavanje korištenjem infracrvene termografije i umjetne referentne površine.....	22
2.4.1. Uvod.....	22
2.4.2. Mjerenja	23
2.4.3. Obrada podataka i rezultati	24
2.5. Termografsko snimanje i sastav izotopa ugljika indiciraju razlike u provodnosti puči i iskoristivoj uporabi vode između sorti jagoda (<i>Fragaria x ananassa</i>).....	26
2.5.1. Uvod.....	26
2.5.2. Mjerenja	27
2.5.3. Obrada podataka i rezultati	28
2.6. Procjena vodnog statusa korištenjem termografije: razvoj višegodišnjeg modela uz korištenje termografskih snimaka s tla	32
2.6.1. Uvod.....	32
2.6.2. Mjerenja	32
2.6.3. Obrada podataka i rezultati	34
2.7. Otkrivanje prostornih i vremenskih promjena u vodnom statusu vinove loze termografskim snimanjem	39
2.7.1. Uvod.....	39
2.7.2. Mjerenja	40

2.7.3. Obrada podataka i rezultati	42
3. ANALIZA KORIŠTENIH METODA	44
3.1. Analiza metoda termografskog snimanja.....	44
3.1.1. Uvod.....	47
3.2. Analiza metoda obrade podataka	50
3.3. Analiza rezultata	52
3.4. Analiza potencijala primjene	53
4. TERMOGRAFSKO SNIMANJE PRESADNICA PAPRIKE (<i>Capsicum annuum</i> L.)	55
4.1. Mjerna linija.....	55
4.2. Rezultati mjerenja	58
4.3. Analiza rezultata mjerenja	63
5. TERMOGRAFSKO SNIMANJE PRESADNICA RAJČICE (<i>Lycopersicon esculentum</i> Mill.)	68
5.1. Mjerna linija za termografiju	70
5.2. Ostale mjerne linije	74
5.2.1. Mjerenje vodnog potencijala lista	74
5.2.2. Mjerenje fotosinteze.....	75
5.3. Rezultati mjerenja	76
5.3.1. Rezultati mjerenja termoparovima.....	76
5.3.2. Rezultati termografskog mjerenja	79
5.3.3. Rezultati mjerenja vodnog potencijala.....	82
5.3.4. Rezultati mjerenja fotosinteze.....	83
5.4. Analiza rezultata	83
6. RAZVOJ MODELA VEZE IZMEĐU CWSI I LWP ZA RAJČICU	87
6.1. Model za potpuno automatsku obradu	87
6.1.1. Prosječna temperatura kao ϑ_i i minimalna temperatura kao ϑ_{wet}	89
6.1.2. Prosječna temperatura kao ϑ_i i $\vartheta_{10\%}$ kao ϑ_{wet}	90
6.1.3. Medijan temperature kao ϑ_i i minimalna temperatura kao ϑ_{wet}	91
6.1.4. Medijan temperature kao ϑ_i i $\vartheta_{10\%}$ kao ϑ_{wet}	92
6.2. Model za potpuno automatsku obradu sa selekcijom piksela	93
6.3. Model s grubom ručnom selekcijom piksela	96
6.3.1. Ponovljena iteracija grube metode.....	98
6.4. Model s finom ručnom selekcijom piksela	99
6.5. Model s referentnim temperaturama pripremljenih listova.....	101
6.6. Model za mikorizirane biljke	104
6.7. Model za nemikorizirane biljke	105
6.8. Analiza razvijenih modela	106
7. ZAKLJUČAK.....	108
LITERATURA.....	110
PRILOZI.....	112

POPIS SLIKA

Slika 1.	Shema za prikaz prostorne razlučivosti[1]	5
Slika 2.	Rezultati CWSI-LWP analize[2]	10
Slika 3.	Usporedba termograma i digitalne fotografije[3]	12
Slika 4.	Korelacija rezultata za mjerenja g_s i I_G [3]	14
Slika 5.	Korelacija rezultata za mjerenja LWP i CWSI[4]	19
Slika 6.	Dobivena karta LWPa na osnovu termografskog snimanja[4]	20
Slika 7.	Usporedba mjerenih i modelom predviđenih vrijednosti LWPa[4]	21
Slika 8.	Kamera postavljena na raspršivaču[5]	23
Slika 9.	Veza između mjerenih vrijednosti LWPa i CWSIa[5]	25
Slika 10.	Digitalna i termografska snimka jagoda tijekom mjerenja[6]	27
Slika 11.	Rezultati analize termografskog snimanja jagoda[6]	30
Slika 12.	Tri načina postavljanja kamere za mjerenja[7]	33
Slika 13.	Veza između CWSI _{ARS} i LWP za mjerene podatke[7]	35
Slika 14.	Veza između CWSI _{ARS} i LWP za različite faze rasta biljke[7]	37
Slika 15.	Veza između CWSI _{ARS} i LWP za različite sorte pamuka[7]	38
Slika 16.	Dobivena karta LWPa na osnovu termografskog snimanja[7]	38
Slika 17.	Evaposensor, komercijalna referentna površina[8]	40
Slika 18.	Korištenje Evaposensora tijekom mjerenja[8]	41
Slika 19.	Mjerna linija za mjerenje na paprikama	56
Slika 20.	Položaj kamere	57
Slika 21.	Postavljanje termoparova u uzorke	58
Slika 22.	Temperature za navodnjavani uzorak mjerene termoparovima	59
Slika 23.	Temperature za nenavodnjavani uzorak mjerene termoparovima	59
Slika 24.	Temperature lista dobivene mjerenjem termoparovima	60
Slika 25.	Snimljeni termogrami tijekom mjerenja na paprici	61
Slika 26.	Snimljeni termogrami tijekom mjerenja na paprici	62
Slika 27.	Temperature lista dobivene termografskim snimanjem	63
Slika 28.	Vrijednosti CWSI prema mjerenju termoparovima	64
Slika 29.	Vrijednosti CWSI prema termografskom mjerenju	65
Slika 30.	Vrijednosti CWSIa za različite suhe referentne temperature	66
Slika 31.	Vrijednosti CWSIa za novu suhu referentnu temperaturu	67
Slika 32.	Presadnice u plasteniku rasadnika Longo, Rovinj	69
Slika 33.	Rajčice presađene u sadne lončice	70
Slika 34.	Prikaz jednog uzorka za mjerenje	71
Slika 35.	Mjerna linija za rajčice	71
Slika 36.	Odabrane biljke za mjerenje termoparovima	72
Slika 37.	Položaj termoparova u biljci	73
Slika 38.	Mjerna linija za vodni potencijal lista	75
Slika 39.	Mjerna linija za fotosintezu	76
Slika 40.	Temperature mjerene termoparovima za navodnjavani mikorizirani uzorak	77
Slika 41.	Temperature mjerene termoparovima za navodnjavani nemikorizirani uzorak	77
Slika 42.	Temperature mjerene termoparovima za nenavodnjavani nemikorizirani uzorak	78
Slika 43.	Temperature mjerene termoparovima za nenavodnjavani mikorizirani uzorak	78
Slika 44.	Temperature u stabljici kod lista svih uzoraka mjerene termoparovima	79
Slika 45.	Snimljeni termogrami tijekom mjerenja na rajčici	80
Slika 46.	Primjena filtera na termogramima rajčice	81
Slika 47.	Temperature lista rajčice dobivene termografskim snimanjem	81
Slika 48.	Vrijednosti CWSI za rajčice prema mjerenju termoparovima	84

Slika 49.	Vrijednosti CWSI prema termografskom mjerenju rajčice.....	85
Slika 50.	Veza CWSI-LWP za slučaj 6.1.1.	89
Slika 51.	Veza CWSI-LWP za slučaj 6.1.2.	90
Slika 52.	Veza CWSI-LWP za slučaj 6.1.3.	91
Slika 53.	Veza CWSI-LWP za slučaj 6.1.4.	92
Slika 54.	Veza CWSI-LWP za slučaj 6.2. prema Meronu	93
Slika 55.	Promjena stupnja korelacije s porastom gornje granične vrijednosti.....	94
Slika 56.	Promjena stupnja korelacije sa smanjenjem donje granične vrijednosti	95
Slika 57.	Proces grube selekcije područja termograma	96
Slika 58.	Veza CWSI-LWP za slučaj 6.3.	97
Slika 59.	Izmijenjeni proces grube selekcije područja termograma	98
Slika 60.	Veza CWSI-LWP za slučaj 6.3.1.	99
Slika 61.	Proces fine selekcije područja termograma	100
Slika 62.	Veza CWSI-LWP za slučaj 6.4.	100
Slika 63.	Prikaz referentnih listova na termogramima	102
Slika 64.	Veza CWSI-LWP za slučaj 6.6.	103
Slika 65.	Veza CWSI-LWP za slučaj 6.6.	104
Slika 66.	Veza CWSI-LWP za slučaj 6.6.	105

POPIS TABLICA

Tablica 1. Usporedba termografskih postavki raznih autora.....	45
Tablica 2. Svojstva korištene termografske kamere.....	56
Tablica 3. Pregled izmjerenih vrijednosti LWPa	82
Tablica 4. Pregled izmjerenih vrijednosti A i g_s	83
Tablica 5. Pregled vrijednosti u analizi pod 6.5.	102
Tablica 6. Pregled razvijenih modela	106

POPIS OZNAKA

Oznaka	Jedinica	Opis
LWP	MPa	Vodni potencijal lista
CWSI	-	Indeks vodnog stresa krošnje
T	K	Termodinamička (apsolutna) temperatura
σ	W/(m ² K ⁴)	Boltzmannova konstanta, $5,667 \cdot 10^{-8}$ W/(m ² K ⁴)
ε	-	Faktor emisivnosti
E	W/m ²	Vlastito emitirano zračenje
x	m	Visina snimanog objekta
l	m	Udaljenost od objektiva kamere
α	rad	Prostorna razlučivost kamere
ϑ_i	°C	Izmjerena temperatura
ϑ_{wet}	°C	Donja granica temperature krošnje
ϑ_{dry}	°C	Gornja granica temperature krošnje
ϑ_{air}	°C	Temperatura okolišnog zraka
ϑ_{min}	°C	Minimalna temperatura
ϑ_{max}	°C	Maksimalna temperatura
ϑ_{span}	°C	Temperaturni raspon na termogramu
$\vartheta_{(x,y)}$	°C	Temperatura piksela na koordinatama x,y
$GL_{(x,y)}$	-	Nijansa sive (računalno definirana numerička vrijednost)
I_G	-	Temperaturni indeks lista
g_s	mmol/(m ² s)	Provodnost puči
r_s	s/m	Otpor lista gubitku vode
ϑ_{leaf}	°C	Temperatura lista
ϑ_{NI}	°C	Temperatura krošnje nenavodnjavane biljke
ϑ_{FI}	°C	Temperatura krošnje biljke navodnjavane u suvišku
$I_{NI/FI}$	-	Temperaturni indeks lista obzirom na krošnju
$CWSI_{NI/FI}$	-	Indeks vodnog stresa krošnje prema referentnoj krošnji
HCWSI	-	Histogramski indeks vodnog stresa krošnje
f_T	-	Frekvencija temperaturnog razreda T
$dist_T$	-	Normalizirana vrijednost temperature
ϑ_{canopy}	°C	Izmjerena temperatura krošnje
ϑ_{pixel}	°C	Temperatura u promatranom pikselu termograma
N	-	33% piksela zadržanih nakon prvog koraka
f_i	-	Broj piksela u i-tom razredu histograma
ϑ_{ARS}	°C	Temperatura umjetne referentne površine
WUE	-	Učinkovitost iskorištenja vode
ρ	kg/m ³	Gustoća zraka
c_p	J/(kgK)	Specifični toplinski kapacitet zraka

s	Pa/K	Nagib krivulje zasićenosti vodene pare s tlakom
D	Pa	Deficit tlaka vodene pare
γ	Pa/K	Psihrometrijska konstanta
R_{ni}	W/m ²	Neto izotermna radijacija za list pri temperaturi zraka
r_{aW}	s/m	Otpor graničnog sloja prolasku pare
Ψ_{stem}	MPa	Vodni potencijal stabljike

SAŽETAK

U ovome radu provedeno je istraživanje na uzorcima presadnica industrijske rajčice (*Lycopersicon esculentum* Mill.) i paprike (*Capiscum annuum* L.). Mjerenja temperature su provedena termoparovima i infracrvenom termografskom kamerom. Na uzorku rajčice su provedena i mjerenja bioloških svojstava biljke poput vodnog potencijala lista (LWP). Analizirana je promjena temperature i indeksa vodnog stresa usjeva (CWSI) tijekom dana. Na osnovu vrijednosti CWSIa dobivenih pomoću više modela analize i mjerenih vrijednosti LWPa napravljeno je više modela koji opisuju vezu tih dviju vrijednosti. Dobiveni modeli su pokazali statistički značajan stupanj korelacije između tih vrijednosti. Vrijednosti CWSIa dobivene ručnom obradom termograma su se dale najveći stupanj korelacije, no i neke automatske metode obrade su pokazale usporedive rezultate s ručnima. Zaključeno je da je uz korištenje metode automatskog termografskog snimanja koja proizvodi termograme dovoljno visoke kvalitete automatska obrada termograma za izračun CWSI pouzdano primjenjiva.

Ključne riječi: infracrvena termografija, navodnjavanje, indeks vodnog stresa usjeva, vodni stres

SUMMARY

Research was conducted on samples of tomato (*Lycopersicon esculentum* Mill.) and bell pepper (*Capiscum annuum* L.) plants. Temperature measurements were carried out using thermocouples and an infrared thermal imaging camera. Biological properties of the plant, such as the leaf water potential (LWP), were measured only on the sample of tomatoes. For both samples, an analysis of the change of temperature and crop water stress index (CWSI) during the day was conducted. For the tomato sample the obtained CWSI values and the measured LWP values were used to create multiple models describing their relationship. The obtained relationships showed a statistically significant degree of correlation. Values of CWSI obtained by manual analysis of thermal images produced the highest degree of correlation, but some of the automatic analysis methods produced results comparable to those obtained using the manual methods of analysis. It was concluded that if an automatic thermal imaging method which produced thermal images of sufficiently high quality is used, then the automatic method for the calculation of CWSI developed here is confidently applicable.

Key words: infrared thermography, irrigation, crop water stress index, water stress

1. UVOD

Voda je jedan od osnovnih uvjeta za postojanje života, te je kao takva jedan od najvažnijih resursa na planetu. Zahvaljujući rastućem broju stanovnika, intenzivnom navodnjavanju usjeva i klimatskim promjenama ovaj resurs je sve više tražen i ujedno sve manje dostupan. Tako nekada značajne rijeke, poput Colorada, Amu i Syr Darye, Inda, Gangesa, Fena, Huang Hea (Žute rijeke) ili Nila, danas do svojih ušća dolaze s malim djelićem negdašnjeg protoka ili čak uopće nemaju nikakav protok kod ušća. U navedenim slučajevima većina vode iz tih rijeka se odvodi za navodnjavanje poljoprivrednih površina. Jasno je da staništa u donjim tokovima tih rijeka tada nestaju i dolazi do ekološke katastrofe. Iz ovog razloga potrebno je razviti metode kojima bi se smanjila potrebna voda za navodnjavanja poljoprivrednih usjeva, a u tom smislu je važan korak optimiziranje procesa navodnjavanja da bi se izbjeglo pretjerano navodnjavanje kada za njime nema potrebe. Osim toga, optimizacijom ovog procesa se mogu ostvariti značajne financijske uštede u uzgoju i povećati kvaliteta konačnog proizvoda.

Da bi se moglo točno upravljati količinom vode kojom se navodnjava usjev potrebno je poznavati potrebu promatranog usjeva za navodnjavanjem u pojedinom trenutku. Upravo u ovome zahtjevu se nalazi ograničenje koje sprječava bolju optimizaciju procesa navodnjavanja. Naime, sadašnja tehnologija zahtjeva mjerenja na individualnim biljkama na terenu, što je proces koji je vremenski zahtjevan i ne daje detaljnu sliku za svaku pojedinu biljku, nego pretpostavlja da je odabrani uzorak dovoljno reprezentativan za cijeli dio polja. To naravno ne mora biti slučaj jer prirodne varijacije u tlu i drugim okolišnim faktorima mogu stvoriti lokalne varijacije. Kada bi se ove varijacije mogle precizno otkriti moglo bi se navodnjavati samo pojedine manje dijelove polja, ili čak pojedine biljke na polju, čime bi se smanjila potrošnja vode izbjegavanjem nepotrebnog zalijevanja već dovoljno zalivenih biljaka.

U sklopu ovoga rada istražena je primjena infracrvene termografije kao metode za otkrivanje ovih varijacija na presadnicama povrća. Infracrvena termografija je beskontaktna i za uporabu jednostavna mjerna metoda koja se može automatizirati. Formalno, ova metoda je definirana kao beskontaktna metoda mjerenja i bilježenja temperature i njezine raspodjele na površinama objekata. Njen naziv potječe od grčkih riječi *therme* – toplina i *grafein* – pisati. Time se podrazumijeva da nakon mjerenja ostaje trajan zapis o izmjerenoj dozračenoj količini energije s promatrane površine: termogram. [1]

Zahvaljujući tome što je termogram danas digitalan zapis koji se može odgovarajućim programskim rješenjima analizirati na računalu moguća je računalna automatizacija tog procesa ako se snima poznati uzorak. To znači da se metoda može, uz razvoj kompletnog softverskog rješenja i odgovarajuće održavanje, upotrebljavati u širokoj primjeni i od strane poljoprivrednika koji nisu termografisti po struci.

Kako se količina vode za navodnjavanje u pravilu određuje prema mjerljivim biološkim karakteristikama biljke, tada je potrebno vrijednosti dobivene termografskim snimanjem odgovarajućim modelom povezati s relevantnim biološkim veličinama. Kako svaka poljoprivredna kultura ima svoje specifične zahtjeve za vodom, a pogotovo uzevši u obzir da se ti zahtjevi mogu mijenjati tijekom različitih fenofaza životnog ciklusa biljke, tada je potrebno istraživanje provesti zasebno za svaku kulturu da bi se mogli dobiti relevantni modeli koji povezuju temperaturne i biološke značajke.

U radovima se biljka često opisuje kao kolona koja provodi vodu iz tla do atmosfere. U uvjetima suše zbog smanjene količine vode u tlu korijen biljke ne prima vodu i ne provodi ju dalje u atmosferu. Time se gubi kontinuum nadomjestka vode izgubljene transpiracijom u biljci. Vodni deficit može poremetiti mnoge stanične i organske funkcije biljke, te imati negativan utjecaj na njen rast i razmnožavanje. U slučaju kada takav nedostatak vode u okolišu nanosi štetu biljci tada se naziva vodnim stresom.[12]

Biljke se mogu kratkotrajno prilagoditi vodnom deficitu promjenom fizioloških i kemijskih procesa. Pri tome važnu ulogu u prilagodbi na vodni deficit preuzima plojka lista koja osim što obavlja fotosintetsku aktivnost ima funkciju i u izlučivanju vode. Kao odgovor na vodni deficit puči, što je naziv za pore na listu kroz koje se obavlja izmjena fluida s okolinom, se zatvaraju da bi se spriječio gubitak vode i prekinuo proces transpiracije. Prekidanjem ovog procesa dolazi do prekida evaporativnog hlađenja lista, te njegova temperatura raste. S druge strane list biljke koja nije izložena vodnom deficitu, nego je navodnjavana u suvišku će imati potpuno otvorene puči i puni intenzitet transpiracije čime će se temperatura lista približiti temperaturi vlažne izoterme za trenutno stanje zraka u okolišu. [11]

U komercijalnoj primjeni se stanje opskrbljenosti biljaka vodom određuje provođenjem mjerenja vodnog potencijala lista (eng. leaf water potential, LWP) na nekoliko odabranih biljaka koje ne moraju nužno dati dobru sliku cijelog usjeva na tom polju.[3] I u ovom radu će se LWP usvojiti kao ključni biološki faktor s kojime će se povezivati izmjerene temperature, tj. na osnovu njih izračunate temperaturne značajke biljke. Ovaj model će u suštini prikazivati odnos temperature lista presadnice i njenog vodnog stresa.

Drugo važno biološko svojstvo na koje utječe vodni stres je provodljivost puči. Biljka koja je izložena vodnom stresu zatvara svoje puči i privremeno prekida proces fotosinteze. To ima nepovoljan utjecaj na biljku i u konačnici na prinose i kakvoću uroda. Iz tog razloga je važno utvrditi točan utjecaj intenziteta vodnog stresa na provodljivost puči, a u ovom radu je proučena mogućnost korištenja termografski izmjerene temperature za ocjenu provodljivosti puči biljke u danom trenutku.

Na osnovu tako razvijenih modela se zatim može napraviti usporedba između presadnica na kojima je primijenjena, odnosno nije primijenjena, mikoriza. Pri tome je značajno odgovoriti na pitanje je li za obje vrste presadnica moguća primjena istog modela, odnosno u kojoj mjeri i na koji način mikoriza mijenja odnos temperaturnih značajki biljke i vodnog stresa kojemu je biljka izložena.

Provedbom gore navedenih mjerenja i analiza steći će se bolji uvid u povezanost ovih fizikalnih veličina, te napraviti podloga za razvoj komercijalnog rješenja koje bi moglo u praktičnoj primjeni zamijeniti postojeće metode upravljanja navodnjavanjem.

1.1. Osnove termografskog mjerenja

Infracrvena termografija je beskontaktna metoda određivanja temperature na temelju mjerenja iznosa zračenja koje dolazi s nekog objekta. Na osnovu tako prikupljenih podataka se, uz poznavanje drugih relevantnih veličina, može dobiti temperatura tog tijela, odnosno temperaturna raspodjela na tom tijelu. Pri tome je važno naglasiti da je temperatura koju termogram prikazuje proračunska vrijednost, a ne izravno mjerena fizikalna veličina. Prikazana numerička vrijednost temperature na termogramu ne ovisi samo o zračenju s objekta, nego i o podacima o emisivnosti objekta, temperaturi okoline i drugim dodatnim parametrima.

To je posljedica činjenice da stvarna tijela nisu idealna crna tijela i iz tog razloga je potrebno definirati emisivnost tijela ε prema Stefan-Boltzmannovu zakonu za stvarna tijela (1):

$$E = \varepsilon * \sigma * T^4 [W/m^2] \quad (1)$$

Pri čemu je E vlastito emitirano zračenje, T je apsolutna temperatura tijela u K, a σ je Boltzmannova konstanta i iznosi $5,667 * 10^{-8} W/(m^2K^4)$. Kako je σ nepromjenjiva fizikalna konstanta, tada se može zaključiti da je upravo emisivnost ključno svojstvo koje se mora

poznavati da bi se mogla izračunati temperatura iz izmjerene vlastitog zračenja zabilježenog kamerom. Emisijski faktor realnog tijela je omjer vlastite emitirane energije realnog tijela pri nekoj odabranoj temperaturi i vlastite emisije crnog tijela pri toj istoj temperaturi, te je stoga uvijek između 0 i 1. [1] U tehničkoj praksi se ova vrijednost najčešće dobiva eksperimentalno ili preuzima iz tablica za poznati materijal. Ona je ujedno i izvor nesigurnosti mjerenja jer odabrana emisivnost ne mora nužno biti jednolika diljem površine objekta, niti, a pogotovo u slučaju tabličnih vrijednosti, adekvatno odabrana.


Samo snimanje termograma je relativno jednostavan postupak. Snimanje se provodi umjerenom termografskom kamerom pri čemu su u softveru kamere unesene sve relevantne postavke koje su ranije spomenute. Pri tome valja uzeti u obzir svojstva same kamere jer se upravo u tim svojstvima kriju ograničenja koja moraju biti ispoštovana tijekom samog snimanja. Ta ograničenja se odnose na prostornu i temperaturnu razlučivost kamere. Osim na svojstva kamere mora se paziti i na njeno ispravno postavljanje prilikom snimanja.

Najvažniji dijelovi kamere, koji definiraju njena svojstva, su leća i detektor. Leća infracrvene kamere mora biti što više propusna za infracrveno zračenje. Najčešće se u tu svrhu koriste leće od germanija (Ge) koji je neproziran u vidljivom dijelu spektra, ali proziran za zračenja valne duljine veće od 2 μm . Osim leća od germanija koriste se i leće od cink sulfida (ZnS), cink selenida (ZnSe), magnezija (Mg), silicija (Si), te leće od safira i kvarca (oboje oblici Al_2O_3 spoja). Zbog potrebe za skupim materijalima poput germanija i finom obradom te leće značajno povećavaju cijenu kamere u odnosu na usporedivu kameru za snimanje u vidljivom spektru. [1]

Detektori su mjerni uređaji koji bilježe intenzitet infracrvenog zračenja koje na njih upadne kroz leću kamere. U prošlosti su to bili sustavi u kojima je detektor bio jedan osjetnik na koji se mehaničkim pomicanjem i korištenjem različitih prizmi unutar kamere usmjeravalo infracrveno zračenje s različitih dijelova vidnog polja. Brzina skeniranja u takvim sustavima je ograničena brzinama i inercijom pokretnih skenirajućih elemenata i ne dozvoljava velike frekvencije obnavljanja slike. Takvi skeneri su također relativno teški i glomazni, što čini kamere koje ih koriste manje primjenjivima za terensku uporabu. Razvojem mikroelektronike ovu vrstu skenera je zamijenio takozvani FPA (eng. *focal plane array*) detektor. [1]

FPA detektor je mikročip pravokutnog oblika u čijoj se matrici nalaze se pojedinačni osjetnici (u pravilu nehladeni bolometarski osjetnici) koji apsorbiraju zračenje iz mjerne točke i daju signal o njegovom intenzitetu softveru kamere. Uz korištenje ovakvog detektora je za snimanje dovoljan samo optički sustav koji s odgovarajućom lećom usmjerava zračenje na

detektor. Prostorna razlučivost definira veličinu najmanjeg objekta kojeg je moguće identificirati na termogramu tj. koji na termogramu u potpunosti ispunjava barem jedan piksel. Ova vrijednost ovisi o finoći skeniranja vidnog polja, broju osjetnika u matrici FPA detektora i o udaljenosti objekta. Prostorna razlučivost se iskazuje vidnim kutom, koji je u pravilu izražen u jedinici miliradijana. Ovo je prikazano na slici 1. [1]



Slika 1. Shema za prikaz prostorne razlučivosti[1]

Kod FPA detektora, obzirom da postoji ograničen broj osjetnika, postoji neka najveća udaljenost l na kojoj će zračenje s promatrane točke zadane veličine x u potpunosti ispuniti barem jedan osjetnik na detektoru, odnosno piksel na termogramu. Drugim riječima prostorna razlučivost definira veličinu najmanje površine koju je moguće jasno identificirati na termogramu s neke udaljenosti l . [1] Postoje kamere koje digitalno interpoliraju vrijednosti između pojedinih mjernih točaka i tako omogućavaju prikaz termograma veće rezolucije od one koju ima detektor, ali te vrijednosti nisu dovoljno pouzdane za znanstvenu primjenu. Iz ovoga se može zaključiti da je za svako preciznije snimanje potrebna kamera veće razlučivosti, a to za sobom povlači i višu cijenu opreme.

Ako se sa α označi prostorna razlučivost u radijanima tada je najmanja visina objekta x koju će na udaljenost l raspoznati osjetnik kamere dana jednadžbom (2): [1]

$$x = 2 * l * \tan\left(\frac{\alpha}{2}\right) \quad (2)$$

U praksi je prostorna razlučivost najčešće reda veličine miliradijana i obično se u dokumentaciji navodi u toj jedinici. To je vrlo malen broj pa samim time vrijedi da je tangens kuta α približno jednak po iznosu kutu α u radijanima. Sada se prethodni izraz može pojednostaviti na (3):

$$x = l * \alpha \quad (3)$$

Prema tome, snimanje objekta visine x s udaljenosti veće od $l * \alpha$ nema smisla jer se neće dobiti relevantni rezultati budući da će piksel na kojemu bi se trebao prikazati mjereni objekt sadržavati zračenje s okolnih objekata, te će kamera dati prosjek tih vrijednosti. Samim time na osnovu takvog snimanja nije moguće izvući nikakav zaključak o temperaturi promatranog objekta.

Položaj kamere i fokus su najvažniji parametri na koji izravni fizički utjecaj ima termografist. U idealnom slučaju kamera bi se trebala nalaziti na odgovarajućoj udaljenosti okomito na promatrani objekt i s objektom izoštreanim u fokusu. U slučaju da je objekt veoma reflektivan u infracrvenom području, tada snimanje nije moguće, no ako je djelomično reflektivan tada je potrebno objekt snimiti iz više kutova da bi se utvrdilo je li uočena nepravilnost stvarna ili je u pitanju refleksija zračenja koje dolazi od nekog vanjskog izvora.

Kod krošnji je gore navedeno teže postići nego kod tipičnih strojarskih instalacija zato što listovi biljaka nisu ravnomjerno orijentirani samo u jednom smjeru nego se nalaze pod većim brojem različitih kutova u odnosu na ravninu na koju je kamera okomito postavljena. Posebna pažnja se mora posvetiti praćenju ovog izvora mjerne nesigurnosti kod provođenja mjerenja na ovakvoj vrsti objekta.

2. PREGLED RANIJIH ISTRAŽIVANJA

U zadnjih desetak i više godina provedeno je nekoliko istraživanja na temu korištenja infracrvene termografije u svrhu određivanja vlage tla i potrebe za navodnjavanjem usjeva. Ovi radovi predstavljaju teoretsku i praktičnu podlogu na osnovu koje je moguć daljnji razvoj ove tehnologije. U ovom poglavlju je predstavljen pregled odabranih radova koji su dali temelj na osnovu kojega se može nastaviti daljnji razvoj metodologije primjene ove tehnologije. Radovi su prikazani u kronološkom redoslijedu nastajanja.

2.1. Procjena vodnog potencijala lista infracrvenim snimanjem i prostornom analizom

2005. godine, u časopisu Journal of Experimental Botany, Cohen i suradnici objavljuju svoj rad pod naslovom „Procjena vodnog potencijala lista infracrvenim snimanjem i prostornom analizom“.

Y. Cohen je znanstvenik s Instituta za poljoprivredno inženjerstvo Organizacije za poljoprivredna istraživanja Volcani centra iz Bet Dagona u Izraelu. Ovo je prvi od dva njegova rada koji će ovdje biti predstavljeni, a dvojica suradnika s ovog rada su također autori još dva druga kasnija znanstvena rada koja su ovdje predstavljena. Time ovdje predstavljeni radovi čine ujedno i pregled razvoja ove tehnologije u Izraelu.

2.1.1. Uvod

Ciljevi rada bili su razvoj modela za procjenu LWP-a na osnovu termografskog snimanja i razvoj procedure za bilježenje vodnog statusa usjeva kombinacijom tog modela i analize prostorne strukture usjeva.

Kao prvi korak istraživanja je veza između LWP-a, temperature krošnje i CWSI-a na listovima pamuka. U radu je CWSI definiran prema jednadžbi (4) koja citira raniji rad Idsa, te Jacksona.

$$CWSI = \frac{\vartheta_i - \vartheta_{wet}}{\vartheta_{dry} - \vartheta_{wet}} \quad (4)$$

Ovdje ϑ_{wet} odgovara temperaturi lista dobro opskrbljenog vodom kojemu su puči potpuno otvorene, a ϑ_{dry} odgovara temperaturi lista kod kojega su puči u potpunosti zatvorene. Cohen napominje da se CWSI nije koristio u praktičnoj uporabi jer su postojali problemi u mjerenju potrebnih temperatura, tj. nije postojala metoda kojom bi se precizno mogle izmjeriti samo temperature krošnji, bez utjecaja tla i ostalog lišća.

Spominje se rad Colaizzija iz 2003. u kojem je CWSI pristup proširen da bi se odredio i indeks navodnjavanosti tla i dubina iscrpljenosti vode u zoni korijena. Time CWSI postaje značajan čimbenik u određivanju točne količine vode za navodnjavanje usjeva.

Problem nesigurnosti mjerenja se može riješiti korištenjem umjetnih referentnih površina (eng. *artificial reference surfaces*, ARS) što je temeljeno na radu Merona, a o čemu će biti više riječi u poglavlju o njegovom radu. Drugi način smanjivanja mjerne nesigurnosti je korištenje dobro navodnjavanih sekcija polja kao reference u mjerenju, te je taj pristup također uspješno primijenjen ranijih godina. Ipak, održati takvu sekciju polja relevantnom za mjerenje je teže izvedivo nego koristiti ARS za ista mjerenja.

2.1.2. Uvod

Mjerenja su provedena u više faza u Kibbutz Shamiru u Izraelu na usjevima pamuka (*Gossypium barbadense* L.). Promatrane biljke navodnjavane su sustavom s kapanjem. Kao referenca korištena je sekcija Tr-D u kojoj su biljke navodnjavane u suvišku, a mjerenja su provedena na sekciji Tr-0 gdje su biljke tijekom rasta navodnjavane standardnom količinom vode koja odgovara njihovoj dnevnoj potencijalnoj evapotranspiraciji. Pred sama mjerenja je režim navodnjavanja promijenjen na tri podsekcije Tr-0, i to tako da je navodnjavanje prekinuto na 2, 4, odnosno 6 dana, čime su nastale sekcije Tr-2, Tr-4 i Tr-6.

Termografsko snimanje izvršeno je kamerom ThermaCAM modela PM545 proizvođača FLIR. Ona je imala detektor rezolucije 320x240 piksela i leću s vidnim kutom od 24°. Kamera je bila postavljena na visini od 5 metara iznad tla i usmjerena okomito prema tlu. Visina stabljike je bila oko jednog metra. To znači da je sukladno jednadžbi (2) jedno mjerno mjesto na detektoru imalo visinu mjerne točke od 5 mm.

Mjerenja LWP-a su napravljena tlačnom komorom, a mjerene vrijednosti su klasificirane u više razreda koji su predstavljali stanja od suficitarnog zalijevanja do ozbiljnog nedostatka vode. Meteorološki podatci su mjereni na lokaciji u intervalima od 10 s, a za račun su korišteni prosječni podatci za svaku minutu. ϑ_{wet} je određen iz termografskih snimaka u kojima je u krošnje umetnut ARS. ϑ_{dry} je procijenjen, sukladno ranijim istraživanjima, prema jednadžbi (5):

$$\vartheta_{\text{dry}} = \vartheta_{\text{air}} + 5 \text{ }^{\circ}\text{C} \quad (5)$$

Snimljeni termogrami su bili u FLIRovom vlastitom formatu, te su prije obrade prebačeni korištenjem FLIRovog softvera u BMP format, a zatim korištenjem Adobeovog Photoshopa u nekomprimirani 8-bitni TIFF format. Za obradu je korištena skala s nijansama sive. Svaka nijansa je pritom predstavljala izmjerenu temperaturnu razliku od 0,1 $^{\circ}\text{C}$, a ukupni raspon 255 nijansa sive je dopuštao temperaturni raspon od 25,5 $^{\circ}\text{C}$. Daljnja obrada tako dobivenih podataka je napravljena korištenjem odgovarajućih softvera, a temperatura svakog pojedinog piksela je računata prema jednadžbi (6):

$$\vartheta_{(x,y)} = \vartheta_{\text{min}} + \frac{\vartheta_{\text{span}}}{255} GL_{(x,y)} \quad (6)$$

Pri čemu je $\vartheta_{(x,y)}$ temperatura na pojedinom pixelu, a $GL_{(x,y)}$ je numerička vrijednost nijanse sive tog piksela.

Mjerenja su provedena tijekom dva dana, jednog u srpnju i drugog u kolovozu 2003. Pri tome su mjerene vrijednosti dobivene u kolovozu korištene za izradu modela, a vrijednosti dobivene u srpnju za provjeru ispravnosti modela.


2.1.3. Obrada podataka i rezultati

Usporedbom rezultata mjerenja za LWP i dobivenih temperatura krošnji iz termograma, a uz provođenje regresijske i prostorne analize njihovog rasporeda u polju, dobivena je karta procijenjenih LWP-a svakog piksela.

Pronađena je dobra korelacija između izravno mjerenih vrijednosti LWP-a i vrijednosti LWP-a predviđenih na osnovu vrijednosti CWSI-a dobivenih iz termograma, pri čemu R^2 iznosi 0,84. Korelacija između vrijednost CWSI-a i LWP-a dana je jednadžbom (7):

$$LWP = -1,73 * CWSI - 1,27 \quad (7)$$

Slika 2 daje grafički prikaz rezultata koji su Cohen i suradnici dobili.



Slika 2. Rezultati CWSI-LWP analize[2]

Prilikom provjere modela dobivenog na osnovu podataka iz kolovoza korišteni su podatci mjerenja iz srpnja. U oba slučaja je pokazano da su sekcije Tr-D, Tr-0 i Tr-2 bile suficitaro navodnjavane, a Tr-4 i Tr-6 su pokazivale znakove vodnog stresa. Rezultati su pokazali da je model očekivano lošije predvidio LWP u srpnju nego u mjesecu za koji je kalibriran. Unatoč tome, i dalje je postojala vidljiva korelacija između istih vrijednosti. Formulirana je hipoteza da bi se trebao razviti sofisticiraniji indeks koji bi uključivao i dnevno vrijeme provedeno pod vodnim stresom, a koji je posljedica toga što su neki listovi osunčani, a drugi djelomično zasjenjeni.

Dodatni podatak koji je zabilježen tijekom istraživanja je da su uočene razlike u površini tla koja je vidljiva pri različitim režimima navodnjavanja. To je posljedica razlike u gustoći listova u krošnji različito navodnjavanih biljaka, te se može koristiti kao indikator u obradi podataka.

2.2. Istraživanje varijabli u korištenju termografskog snimanja za otkrivanje reakcije na vodni stres kod vinove loze u različitim režimima navodnjavanja

2007. godine, u časopisu *Journal of Experimental Botany*, Grant i suradnici objavljuju svoj rad pod naslovom „Istraživanje varijabli u korištenju termografskog snimanja za otkrivanje reakcije na vodni stres kod vinove loze u različitim režimima navodnjavanja“.

O. M. Grant je znanstvenica koja je tada radila u Laboratoriju za molekularnu ekofiziologiju Instituta za kemijsku tehnologiju i biologiju iz Oeirasa u Portugalu. Ovaj rad je kolaboracija sa Sveučilištem u Dundeeu u Škotskoj i Tehničkim Sveučilištem u Lisabonu. Na osnovu varijabli identificiranih u ovom radu Grant je deset godina kasnije objavila drugi rad u kojem opisuje razvoj primijenjene metode termografskog mjerenja kod vinove loze, a koji će biti obrađen u potpoglavlju 3.7.

2.2.1. Uvod

Cilj ovog rada bio je procijeniti termografsko snimanje kao alat za razlikovanje između biljaka pod stresom i onih koje nisu pod stresom, te optimizirati termografsko snimanje za određivanje reakcije biljke na nedostatak vode u polju.

Istraživan je odnos između temperature trsa i provodljivosti puči mjerene porometrom, a isto je istraživanje provedeno i za temperaturu pojedinih listova, te za indekse koji su dobiveni na osnovu mjerenja temperature krošnje i listova.

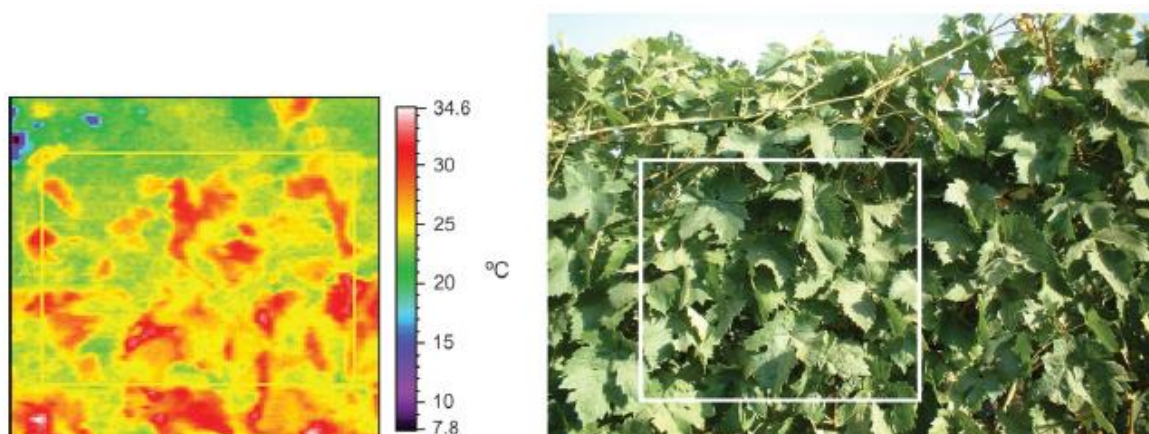
Za snimanje je odabrana vinova loza zato što po svojoj prirodi ima razgranatu krošnju koja je razvedena po vodilicama, te ima velik broj listova koji bi bili okomiti u odnosu na termografsku kameru.

Navodi se da je također potrebno uzeti u obzir da sama orijentacija listova ima veći utjecaj na temperaturu lista kada su puči zatvorenije, nego kada su otvorene i listovi slobodno dišu. Osim toga, navodi se da je u ranijim radovima utvrđeno da postoji veća varijacija u temperaturi između biljaka koje su u istom režimu navodnjavanja kada su izložene vodnom stresu. To je vjerojatno posljedica razlika u svojstvima tla unutar istog polja i razlici u dubini korijenja između pojedinih biljaka.

2.2.2. Mjerenja

Termografsko snimanje je provedeno koristeći kameru IR Snapshot 525 proizvođača Infrared Solutions. Ova kamera ima detektor razlučivosti 120x120 piksela, te temperaturnu razlučivost od 0,1°C. Dobiveni termogrami su analizirani u Infrared Solutionovom softveru SnapView Pro. Za svako mjerenje je temperatura ambijenta određena snimanjem temperature lopte zgužvanog aluminija uz postavljenu emisivnost od 1, što je preporuka proizvođača. Za snimanje krošnji, odnosno listova, korištena je vrijednost emisivnosti od 0,96 u skladu s ranijim radom od Jonesa.

Područja mjerenja su određena usporedbom termograma s odgovarajućom digitalnom fotografijom objekta snimanja, pri čemu su identificirana područja koja su sadržavala samo listove. Usporedni prikaz termograma i digitalne fotografije može se vidjeti na slici 3.



Slika 3. Usporedba termograma i digitalne fotografije[3]

Kamera je bila postavljena na tronožac i okomita na površinu koja je snimana. Snimke su napravljene s udaljenosti od 1,5 i 0,9 metara od površine trsa, čime su zahvaćena područja veličine 500x500 mm i 290x290 mm.

Pri snimanju 2003., kada su snimani pojedini listovi, nije korišten ARS, nego se vlažna referentna temperatura dobila snimanjem listova poprskanih vodom, a suha referentna temperatura se dobila snimanjem listova premazanih petrolejskim gelom (vazelinom) s obje strane. U snimkama cijelih trsova nisu bili korišteni nikakvi referentni listovi.

Pri snimanju 2004. kao referenca korištene su snimke krošnji sa nenavodnjavanog polja za suhu referentnu temperaturu i snimke krošnje s potpuno navodnjavanog polja za vlažnu referentnu temperaturu.

Provodnost puči g_s je mjerena porometrom Li-Cor 1600 proizvođača Li-Cor. Mjerenja su provedena na dvije lokacije u jugoistočnom Portugalu 2003. i 2004. godine. Mjerenja su provedena ujutro i poslijepodne. Ispitivano je više različitih režima navodnjavanja.

2.2.3. Obrada podataka i rezultati

Pri obradi podataka korišten je indeks I_G koji se računa s obzirom na temperaturu lista, a teoretski je proporcionalan provodnosti puči g_s . On je definiran jednačbom (8):

$$I_G = \frac{\vartheta_{dry} - \vartheta_{leaf}}{\vartheta_{leaf} - \vartheta_{wet}} \quad (8)$$

Osim toga, računat je i indeks analogan standardnom CWSI prema Idsu, a definiran prema jednačbi (9):

$$CWSI = \frac{\vartheta_{dry} - \vartheta_{leaf}}{\vartheta_{dry} - \vartheta_{wet}} \quad (9)$$

U obradi podataka iz 2004., gdje su kao referenca korištene cijele krošnje nenavodnjavanih, odnosno dobro navodnjavanih biljaka, temperatura ϑ_{dry} je zamijenjena s temperaturom ϑ_{NI} , a temperatura ϑ_{wet} s temperaturom ϑ_{FI} . Sukladno tome vrijednosti I_G i CWSI za te slučajeve su označene kao $I_{NI/FI}$ i $CWSI_{NI/FI}$ da bi se lakše razlikovale.


Termogrami su prebačeni u Excel tablicu gdje se mogla napraviti analiza svakog piksela. Pikseli koji se promatraju su određeni usporedbom s digitalnom fotografijom. Izračunate su frekvencijske raspodjele temperatura u pojedinim područjima, te prosječna temperatura i varijanca. Konačno, izračunat je histogramski CWSI (HCWSI) prema metodi Brayanta i Morana iz 1999. da bi se otkrilo odstupanje oblika histograma od normalne distribucije s jednakim prosjekom i standardnim odstupanjem. Izmjerena frekvencijska raspodjela temperature je normalizirana izražavanjem frekvencije svakog pojedinog raspona od 0,1 K kao postotka maksimalne frekvencije u promatranom području, čime je dobivena vrijednost f_T .

Za svaki navedeni raspon je zatim računata normalna distribucija prema njegovom prosjeku i standardnom odstupanju, te su same vrijednosti temperature normalizirane tako što su izražene kao postotak od frekvencije maksimalne temperature čime se dobio $dist_T$. Sada je bilo moguće dobiti HCWSI prema jednadžbi (10):

$$HCWSI = \sum_{i=\vartheta_{min}}^{\vartheta_{max}} |(f_T - dist_T) * i| \quad (10)$$

Pri čemu su ϑ_{min} i ϑ_{max} definirane za svaki termogram prema minimalnoj, odnosno maksimalnoj temperaturi piksela na njemu. Dodatno je provedena i statistička analiza podataka pomoću više metoda.

Slika 4 prikazuje korelaciju rezultata između g_s i I_G .



Slika 4. Korelacija rezultata za mjerenja g_s i I_G [3]

Na mjerenjima iz 2003. ta je korelacija pronađena s $p < 0,02$ za mjerenja od jutra 31.07, podneva 13.08. i jutra i podneva 14.08.2003. Za druga provedena mjerenja korelacija nije pronađena. Također se pokazalo da na korelaciju tih vrijednosti nema utjecaj sam iznos g_s , niti izloženost suncu. U nekim slučajevima su dobivene negativne vrijednosti I_G jer je g_{leaf} bio veći od g_{dry} .

U slučajevima kada su snimane cijele krošnje utvrđena je snažna korelacija ($p < 0,02$) između temperature krošnje i statusa navodnjavanja. Potpuno navodnjavana polja su imala krošnje niže temperature nego nenavodnjavana ili smanjeno navodnjavana polja. S druge strane HCWSI je često imao značajnu varijaciju između termograma krošnji na istom polju, pa čak i

između dva termograma iste krošnje snimljena jedan za drugim. U tom smislu nije pronađena nikakva veza između navodnjavanja i HCWSIa.

Na mjerenjima iz 2004. je pronađena jasna korelacija ($p < 0,03$) između izmjerene provodljivosti puči i temperature. Kod ovih mjerenja su se također pojavljivale negativne vrijednosti $I_{NI/FI}$, ali za razliku od mjerenja iz 2003., ovdje su se takve vrijednosti pojavljivale u dva slučaja. Prvi slučaj je kada je krošnja bila pod visokim stresom, pa je njena temperatura bila viša od θ_{NI} . Drugi slučaj je kada je krošnja bila potpuno bez stresa, pa joj je temperatura bila niža od θ_{FI} . Zbog toga se po ovom indeksu ne može procjenjivati stanje krošnje.

Kod korištenog oblika $CWSI_{NI/FI}$ -a je situacija bila drukčija, te su tu vrijednosti manje od 0, odnosno veće od 1, bile jasan znak da je krošnja pod stresom, odnosno da nije pod stresom. Koristeći ovaj oblik $CWSI_{NI/FI}$ -a temperature NI i FI krošnji nisu apsolutno ograničenje temperaturnog raspona, nego samo služe kao indikatori temperature nakon koji nastaje značajan stres, odnosno ne postoji vodni stres biljke. Pronađena je značajna korelacija ovog indeksa ($p < 0,0001$) s količinom navodnjavanja, te značajna negativna korelacija ($p < 0,02$) s provodljivošću puči. Tu ipak treba napomenuti da je provodljivost mjerena samo za jedan list svake promatrane krošnje.

Na temelju gore navedenog autori zaključuju da je termografija potencijalno učinkovita metoda u otkrivanju vodnog stresa biljke. Također navode da se u njihovim mjerenjima pokazalo da promatranje krošnje kao cjeline daje precizniji uvid nego promatranje pojedinih listova, te predlažu daljnje istraživanje kojim bi se ta pretpostavka potvrdila.

Pretpostavka je da snimanje krošnje kao cjeline smanjuje utjecaj nepovoljne orijentacije pojedinih listova i izbjegava greške koje se mogu dogoditi izborom nereprezentativnih listova za mjerenje.

Osim toga zaključuje se da je korištenje referentnih krošnji dalo povoljnije rezultate nego korištenje referentnih listova, a pri čemu se postupak pojednostavljuje i izbjegavaju nesigurnosti povezane s odabirom i pripremom pojedinih listova kao referentnih.

2.3. Ocjenjivanje različitih pristupa za procjenu i bilježenje vodnog statusa usjeva pamuka infracrvenom termografijom

2009. godine, u časopisu Precision Agriculture, Alchanatis i suradnici objavljuju svoj rad pod naslovom „Ocjenjivanje različitih pristupa za procjenu i bilježenje vodnog statusa usjeva pamuka infracrvenom termografijom“.

V. Alchanatis je znanstvenik s Instituta za poljoprivredni inženjering Volcani Centra iz Bet Dagona u Izraelu. Ovaj rad je kolaboracija sa Sveučilištem Ben-Gurion iz Negeva, Galilejskim centrom za tehnologiju i Hebrejskim sveučilištem Jeruzalema. Kao i Y. Cohen, on je suradnik na preostalim radovima Izraelskih znanstvenika koji se ovdje obrađuju. Rad se nastavlja na onaj opisan u dijelu 2.1., te preuzima dio teorijskih postavi i potvrđuje dio ranijih pronalazaka.

2.3.1. Uvod

Cilj ovog rada bio je procijeniti i usporediti veći broj potencijalnih pristupa procijeni vodnog statusa usjeva korištenjem termografskih snimki krošnje, a samim time procijeniti i korištenje ove tehnologije za stvaranje karte LWP-a na osnovu koje bi se mogle donositi odluke o rasporedu navodnjavanja.

Ovdje je glavni problem koji je razmatran onaj procjene LWP-a. U mjerenjima se javlja problem utjecaja doba dana na točnost predviđanja LWP-a na osnovu izmjerene temperature. Osim toga, potrebno je usporediti i metodu procijene korištenjem meteoroloških podataka i energijske bilance s metodom procijene na osnovu empirijskog mjerenja temperature ARS-a i okolnog zraka. Uz ovo, u radu se razmatra utjecaj kuta snimanja i prostorne razlučivosti termografske kamere na dobivene rezultate.

Također se javlja potreba za eksperimentalnim potvrđivanjem indeksa izvedenih iz CWSI-a, te kalibriranje temperaturnih indeksa s poznatim i u praksi prihvaćenim vrijednostima LWP-a za širi raspon usjeva.

U skladu s ranijim radom, i ovdje su mjerenja provedena na poljima pamuka u Izraelu.

2.3.2. Mjerenja

Termografsko snimanje je provedeno koristeći kameru ThermaCAM model PM545 proizvođača FLIR. Ova kamera ima detektor razlučivosti 320x240 piksela, leću 24°, te temperaturnu razlučivost od 0,1°C. Kamera je bila postavljena pet metara iznad tla i usmjerena ravno prema tlu. Uz visinu krošnje od oko jednog metra, te uz poznatu prostornu razlučivost kamere, prema jednadžbi (2) dobije se da je na razini krošnje područje od pet milimetara odgovaralo jednom pikselu na termogramu. Ta rezolucija je omogućila da se jasno razlikuje između piksela koji prikazuju listove i piksela koji prikazuju tlo. Termogrami su iz FLIROvog vlastitog softvera prebačeni u nijanse sive istom metodom kao i u dijelu 2.1.2.

Na svakoj snimanoj sekciji je odabrano pet najmlađih potpuno razvijenih listova i njihova peteljka je označena aluminijskom folijom da bi se mogli identificirati na termogramu. Nakon snimanja termograma ti listovi su odsječeni i njihov LWP je izmjeren uz korištenje tlačne komore. Mjerenja su provedena tijekom jutra i tijekom solarnog zenita.

Sunčevo zračenje, brzina vjetra, temperatura zraka i relativna vlažnost su mjereni dva metra iznad razine tla, što odgovara otprilike razini od pola metra iznad krošnji. Mjerenja su izvršena na meteorološkoj stanici unutar ispitnog polja. Podatci su prikupljeni u identičnim intervalima i prosjecima kao i u dijelu 2.1.

Za mjerenja je napravljena vlažna umjetna referentna površina (eng. *wet artificial reference surface*, WARS) i postavljena u vidno polje kamere tijekom snimanja. WARS je napravljen tako što je blok ekspaniranog polistirena debljine 50 mm stavljen da pluta na vodi u plitkoj plastičnoj posudi dimenzija 400 x 300 x 120 mm. On je prekrivao većinu površine vode, te je bio sam prekriven slojem dvostrukog vodoupijajućeg poliesterskog materijala debljine 0,5 mm. Preko tog sloja je bio dodatni sloj vodoupijajućeg poliesterskog platna debljine 2 mm. Rubovi platna su bili umočeni u vodu te su kapilarno upijali vodu osiguravajući da cijela površina platna bude stalno navlažena. Ovakvo rješenje je omogućilo da je površina savršeno vertikalno i horizontalno položena, te je njime osigurana stalno vlažna površina ponovljivih radiometrijskih i fizikalnih svojstava. S obzirom na to da je platno bilo veoma tanko njegova toplinska inercija je bila zanemariva.

Prosječna temperatura na cijeloj površini WARS-a je korištena kao ϑ_{wet} za proračune tijekom obrade podataka. ϑ_{dry} je u skladu s prethodnim radovima, pretpostavljena na temperaturu zraka uvećanu za 5 °C.

Dodatno mjerenje je provedeno na poljima pamuka u Kibbutzu Revadim na sjeveru Negeva u kolovožu 2005. Na polju su postojale sekcije s tri različita režima navodnjavanja. Termografske snimke su načinjene s dizalice na visini od 20 metara. Kamera je bila postavljena pod kutom od 60° od vertikale, a upotrebljena je širokokutna leća (45°). U ovom slučaju je prostorna razlučivost bila oko pedeset puta slabija nego pri snimanju s pet metara visine, a zbog kuta kamere je dodatno varirala između bližeg i udaljenijeg dijela polja. S druge strane ovakvo snimanje je omogućilo da se cijela površina polja dimenzija 60 x 80 m može zahvatiti u jednom snimku.

Prilikom ovog snimanja nije se moglo koristiti WARS, tako da je ϑ_{wet} određen kao najniža temperatura krošnje na snimci, a ϑ_{dry} je bio aproksimiran prema temperaturi zraka isto kao i kod mjerenja na 5 metara visine.

2.3.3. Obrada podataka i rezultati

CWSI za obradu podataka je računat po formuli (11), prema Jonesovom radu iz 1991., koja je analogna originalnoj formuli po Idsu (4). Uvedena je razlika u tome što se umjesto temperature lista koristi temperatura krošnje.

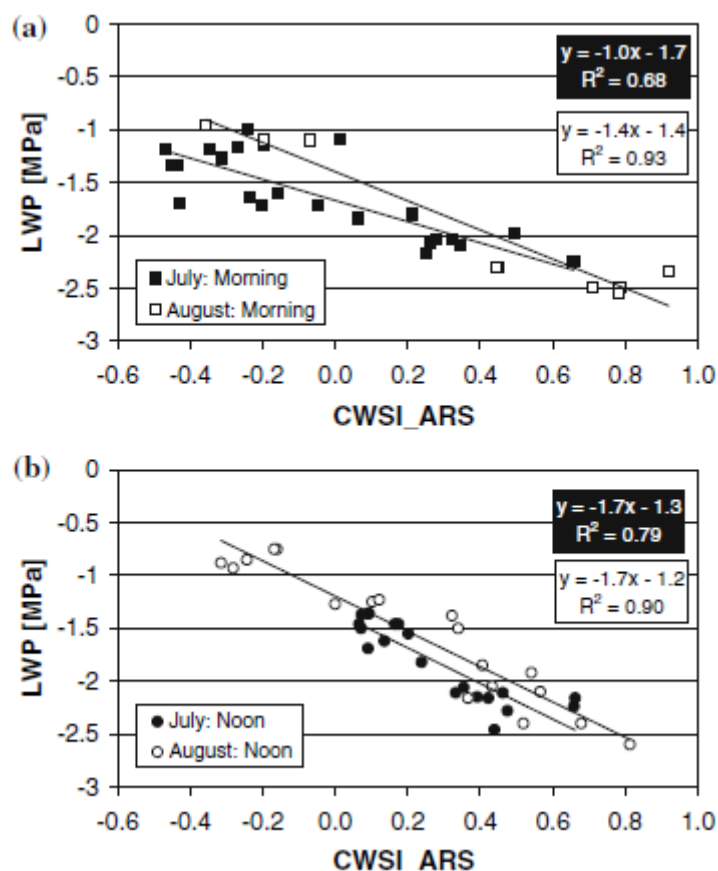
$$CWSI = \frac{\vartheta_{canopy} - \vartheta_{wet}}{\vartheta_{dry} - \vartheta_{wet}} \quad (11)$$

CWSI se osim na osnovu izmjerenih temperatura prilikom termografskog snimanja, računao i na osnovu teoretskih izraza po Jonesu koji procjenjuju vrijednost CWSI-a uz poznate okolišne uvjete i svojstva lista. U radu su vrijednosti CWSI-a izračunate na osnovu mjerenih vrijednosti temperatura označene s podindeksom ARS, a one izračunate na osnovu teoretskih vrijednosti suhe i vlažne referentne temperature imaju podindeks I_2 .

Izmjereni LWP i izračunati CWSI su pokazali dobro slaganje s očekivanim vrijednostima, te su očekivano pokazali negativnije vrijednosti LWP-a i veće vrijednosti CWSI-a kod biljaka koje su bile izložene dužim periodima bez navodnjavanja.

Kako su mjerenja provedena u jutro i podne, tako je i u obradi podataka korištenjem statističkog modela linearne regresije napravljena usporedba LWP-a i CWSI-a za ta dva seta podataka. Na osnovu dobivenih rezultata je zaključeno da se veza između LWP-a i CWSI-a razlikovala za različita mjerenja u jutarnjim satima, no da je veza između LWP-a i CWSI-a u podnevnim satima bila stabilna u svim mjerenjima.

Slika 5 prikazuje usporedbu podataka za jutarnja mjerenja i podnevna mjerenja za svaki od promatranih termina.



Slika 5. Korelacija rezultata za mjerenja LWP i CWSI[4]


Kada se analiza provede uzimajući kao osnovu mjerene rezultate dobivene u oba termina, pokazuje se da je standardna pogreška manja za podatke dobivene mjerenjima u podne nego za podatke mjerene ujutro. Na osnovu toga se može zaključiti ($p < 0,05$) da su mjerenja provedena u podne pouzdanija osnova za procjenu LWPa nego mjerenja provedena u jutarnjim satima. Ovo je posljedica toga što je reprezentativni LWP u biljkama, posebice pamuku, onaj koji se zabilježi pri maksimalnom dnevnom stresu, a koji se događa oko sunčevog zenita. U jutarnjim satima je ovisnost vodnog stresa o drugim okolišnim uvjetima puno izraženiji i pretpostavljeno je da je upravo to dovelo do različitih korelacija za jutarnja mjerenja. Ovo je u skladu s općeprihvaćenim saznanjima o mjerenjima LWPa.

Usporedbom $CWSI_{ARS}$ i $CWSI_{I2}$ s izmjerenim vrijednostima LWPa došlo se do zaključka da $CWSI_{ARS}$ koji je baziran na empirijski utvrđenim referentnim temperaturama ima bolju korelaciju s izmjerenim vrijednostima LWPa. Tako $CWSI_{ARS}$ ima R^2 od 0,85 i standardnu

pogrešku od 0,20 MPa, dok $CWSI_{I2}$ ima R^2 0,69 i standardnu pogrešku od 0,29 MPa u usporedbi sa setom mjerenih podataka o vodnom potencijalu lista. Nagib krivulje u modelu je veći za $CWSI_{I2}$, te je samim time model puno osjetljiviji na promjenu vrijednosti $CWSI_a$. Slična korelacija se može primijetiti i u usporedbi ovih vrijednosti sa postotkom stvarne transpiracije dobro navodnjavanog usjeva.

U zaključku se navodi da je zbog točnosti rezultata korištenje ARSa poželjnije nego određivanje referentnih temperatura teorijskim putem prema Jonesu. To predstavlja određeno praktično ograničenje na jednostavnost primjene tehnologije jer je potrebno paralelno pomicati i kameru i ARS, ali se time osiguravaju rezultati koji su najviše u skladu sa stvarnim stanjem. Korištenje stacionarnog ARS nažalost ne daje jednako dobre rezultate kao korištenje pokretnog ARSa, a primijećen je i malen nepovoljan utjecaj na točnost mjerenja ako se ARS ne postavi u samu krošnju nego u prolaz pored nje. U oba slučaja su mjerne nesigurnosti manje nego nesigurnosti koje unose pretpostavke u teorijskom modelu. Osim toga izbjegava se potreba za detaljnijim meteorološkim mjerenjima mikroklimе na više raznih dijelova polja jer ARS zahtjeva samo mjerenje prostorno uravnotežene i slabo promjenjive temperature zraka.

Slika 6. prikazuje dobivenu kartu LWPa na osam sekcija polja dobivenu na osnovu širokokutne snimke cijelog polja.




Slika 6. Dobivena karta LWPa na osnovu termografskog snimanja[4]

Analizom je utvrđeno da dobivena karta LWPa odgovara realnom stanju na terenu, te da se na njoj mogu prepoznati područja na kojima su korišteni različiti režimi navodnjavanja. Tako su područja označena brojem 1 dobivala 100 % potrebnog dnevnog navodnjavanja, područja

označena brojem 2 su dobivala 81 % potrebnog dnevnog navodnjavanja, a područja označena brojem 3 su dobivala samo 63 % potrebnog dnevnog navodnjavanja i bila izložena visokom vodnom stresu.

Slika 7. prikazuje razliku između vrijednosti LWPa dobivenih mjerenjem u polju i vrijednosti koje predviđa model temeljem širokokutnog termograma.



Slika 7. Usporedba mjerenih i modelom predviđenih vrijednosti LWPa[4]

Nagib krivulje koja opisuje odnos između procijenjenog i mjerenog LWPa je statistički značajan ($p < 0,01$), a iznosi 0,95. To znači da model blago podcjenjuje vrijednosti vodnog potencijala lista u odnosu na stvarno stanje. Razlike između modela i stvarnih vrijednosti se mogu dijelom objasniti kroz samu metodu nastanka modela koji je napravljen prema podacima iz područja na višim nadmorskim visinama i uz korištenje kamere vertikalno postavljene prema krošnji, dok je u ovom slučaju snimanje bilo pod kutom i u primorskoj klimi.

Za snimanje cijelog polja odjednom je za izračun CWSIa nužno koristiti kao referencu temperaturu krošnje dobro navodnjavanog dijela polja, a ne ARSa. Tako dobiveni podatci se mogu smatrati pouzdanima jer predviđanja na osnovu njih dobro odgovaraju stvarnim mjerenjima LWPa.

Autori predlažu da se u sljedećem koraku provede detaljno mjerenje na različitim geografskim i meteorološkim lokacijama, te usporedba različitih sorti pamuka. Ovakvo mjerenje je kasnije provedeno i bit će obrađeno u dijelu 2.6.

2.4. Bilježenje vodnog stresa usjeva za lokacijski upravljano navodnjavanje korištenjem infracrvene termografije i umjetne referentne površine

2010. godine, u časopisu *Precision Agriculture*, Meron i suradnici objavljuju svoj rad pod naslovom „Bilježenje vodnog stresa usjeva za lokacijski upravljano navodnjavanje korištenjem infracrvene termografije i umjetne referentne površine“.

M. Meron je znanstvenik iz Laboratorija za ekologiju usjeva, MIGAL Galilejskog centra za tehnologiju iz Kiryat Shmona u Izraelu. Ovaj rad je kolaboracija s Volcani Centrom. On je sudjelovao kao suradnik na preostalim radovima izraelskih znanstvenika koji se ovdje obrađuju, a specifično se bavio umjetnim referentnim površinama.

2.4.1. Uvod

Danas postoje lokalne metode mjerenja pojedinih veličina na usjevu s bežičnim prenošenjem očitavanja do središnje točke, što su pokazali Peters, Evett i Kim. Primjena takvih rješenja omogućuje uključivanje prostorne varijabilnosti unutar samog polja u analizu. No primjena takvih rješenja na cijelom polju nije financijski isplativa s danas dostupnim proizvodima i razinom tehnologije. radi, što su pokazali Schmitz, Kuyper i Sourell,

U razvoju termografije kao alternativne metode potrebno je odrediti dobre temeljne reference na osnovu kojih se mogu odrediti vlažna i suha referentna temperatura za izračun CWSIa. Korištenje pojedinih dijelova polja koje su održavane u specifičnim (obično dobro navodnjavanim) uvjetima daje dobre rezultate, no njihovo održavanje je zahtjevno i ograničava primjenu u komercijalnoj proizvodnji. Referentne temperature koje se dobiju vlaženjem ili premazivanjem pojedinih listova su u pravilu jedino korisne za metode temeljene na malim uzorcima, a ne velikoj skali cijelog polja. Ovlažene umjetne referentne površine su nasuprot tome dobro definirani i ponovljivi indikatoru uvjeta okoliša, iako imaju određena ograničenja pri neturbulentnim brzinama vjetra.

Područje koje se termografski snima je definirano svojim dimenzijama i brzinom snimanja. Veličina polja je određena prostornom razlučivošću tako da se mora postići dovoljna razlučivost da se omogući raspoznavanje tla od krošnji, te temperaturnih varijacija u samim krošnjama. Zbog toga je u pravilu potrebno da jedan piksel odgovara površini koja je najviše jednaka polovici širine reda usjeva.

Brzina snimanja je ograničena svojstvima kamere pri čemu kamere s bržom akvizicijom slike mogu trpjeti veće brzine leta kada su postavljene na letjelicu. Javlja se problem da su bolometarske kamere prespore da bi mogle proizvesti dobre snimke pri željenim brzinama snimanja. Tada se ili mora smanjiti brzina da bi se izbjeglo mućenje slike ili koristiti softver koji može kompenzirati i tu pojavu i širenje piksela u smjeru gibanja kamere. Radi ekonomičnosti snimanja, koje je definirano brzinom, moguće je preskočiti snimanje određenih sekcija polja i interpolirati podatke iz okolnih snimljenih sekcija.

Cilj ovog rada je bio da se ustanovi veza između svojstava usjeva pod vodnim stresom i daljinski mjerenog toplinskog indeksa, te da se istraži izvodivost bilježenja stresa usjeva pomoću termografije da bi se na osnovu dobivenih podataka upravljalo navodnjavanjem.

2.4.2. Mjerenja

Termografsko snimanje je provedeno koristeći kameru SC2000 proizvođača FLIR. Kamera je imala širokokutnu 45° leću. Pri snimanju s krila raspršivača sredstva za zaštitu bilja kamera je bila postavljena na visini od pet metara iznad razine usjeva, tri metra lijevo od kabine raspršivača i usmjerena ravno 180° od zenita. Kamerom se upravljalo pomoću FLIR ThermaCam softvera na laptopu. Za određivanje pozicije kamere korišten je GPS prijamnik s preciznošću od 1 do 3 metra. Snimke su rađene svake sekunde i povezivane s lokacijom usporedbom vremenskih indeksa slike i zabilježenog položaja na GPS-u.

Slika 8. prikazuje kameru postavljenu za snimanje na raspršivaču.



Slika 8. Kamera postavljena na raspršivaču[5]

Za snimanje iz zraka ista kamera je bila usmjerena ravno dolje iz poda zrakoplova, a GPS antena je bila postavljena na vjetrobranu zrakoplova. Uzevši u obzir interval bilježenja GPSa koji je iznosi 0,20 sekundi, tada je uz brzinu leta od 40 m/s točnost mjerenja GPSom bila ± 8 metara. Kamera je snimala brzinom od 2 slike u sekundi s preciznošću od 0,01 sekunde. Pravac leta zrakoplova je navođen prema vidljivim putovima kroz polje, odnosno zastavicama u poljima koja nisu imala dovoljno vidljive putove. Visina leta je bila 45-50 metara, što je gornja granica za poljoprivredne letove prema izraelskim propisima. Jedan piksel na tako dobivenom termogramu je predstavljao prostor širine 150 mm okomito na smjer leta, ali je zbog „razmazivanja“ slike u smjeru leta zahvaćao prostor od 300 mm.

Za snimanje s tla je korišten ARS koji je postavljen na rub polja usporedno s meteorološkom stanicom koja je korištena za prikupljanje meteoroloških podataka na lokaciji. ARS se sastojao od vlažnog bijelog netkanog platna od viskoznog poliestera koje je u dvostrukom sloju prekrivalo polistirensku plutaču. Plutača je postavljena u plastičnu posudu dimenzija 400 x 300 mm koja je bila ispunjena vodom, a krpa se kapilarnim efektom konstantno ovlaživala pomoću te vode. Posebni infracrveni temperaturni osjetnik postavljen 100 mm iznad ARSa je korišten da bi se bilježila njegova temperatura. Na isto računalo je bila spojena i meteorološka stanica na kojoj se mjerila temperatura i vlažnost zraka, globalno sunčevo zračenje i brzina vjetra na dva metra visine od tla. Vrijednosti su bilježene u intervalima od šest sekundi i pretvarane u prosjeke za svaku minutu.

Mjerenja su provedena u ljeto 2007. godine na usjevu pamuka (hibrid *Gossypium hirsutum x barbadense*) na Polju u dolini Hula u Izraelu. Ono je odabrano jer tlo na ovoj lokaciji uzrokuje različitu prostornu dostupnost vode. Pamuk je zasađen u redovima razmaknutima 0,96 metara i jednoliko navodnjavan sustavom lateralno pomičnih prskalica. Provedeno je šest snimanja na tlu tijekom sezone. LWP je mjeren tlačnom komorom.

2.4.3. Obrada podataka i rezultati

Termogrami su obrađivani u Visual Basicu 5, koristeći OLE automatizaciju koju nudi FLIRov Researcher programski paket. U prvom koraku su napravljeni histogrami snimke s 256 razreda u temperaturnom rasponu 19-45,5 °C s korakom od 0,1 °C. U sljedećem koraku su za obradu zadržani samo oni pikseli koji su spadali u raspon definiran jednadžbom (12). Pri tome se pretpostavljalo da su sve temperature zabilježene izvan ovog raspona nevezane za krošnju pamuka.

$$(\vartheta_{air} - 10) < \vartheta_{pixel} < (\vartheta_{air} + 7) \quad (12)$$

Kumulativni težinski prosjek najhladnijih 33% piksela je računat jednadžbom (13):


$$\vartheta_{canopy} = \frac{\sum_{i=1}^{0,33*N} \vartheta_i * f_i}{\sum_{i=1}^{0,33*N} f_i} \quad (13)$$

Na osnovu ovoga CWSI se računao jednadžbom (14):

$$CWSI = \frac{\vartheta_{canopy} - \vartheta_{ARS}}{\vartheta_{air} + 5^{\circ}C - \vartheta_{ARS}} \quad (14)$$

Pokrivenost usjevom na slici je računata tako što se broj piksela koji zadovoljava uvjete u jednadžbi (12) podijelio ukupnim brojem piksela na termogramu.

Vodni potencijal lista je u mjerenjima pokazao linearnu korelaciju sa CWSIem u punom rasponu vodnog stresa usjeva tijekom perioda mjerenja. Postoji jače rasipanje podataka u području dijagrama koje prikazuje dobro navodnjavane biljke, od ishodišta do CWSI od otprilike 0,4. Ovo rasipanje otežava precizno identificiranje stresa u ovom rasponu. CWSI može pouzdano zamijeniti LWP kao indikator vodnog stresa u biljkama pamuka. Ovaj pronalazak je važan jer ukazuje da se termografijom iz zraka može pouzdano određivati vodni status usjeva na cijelom polju radi upravljanja navodnjavanjem. Slika 9 prikazuje rezultate.



Slika 9. Veza između mjerenih vrijednosti LWP-a i CWSI-a[5]

2.5. Termografsko snimanje i sastav izotopa ugljika indiciraju razlike u provodnosti puči i iskoristivoj uporabi vode između sorti jagoda (*Fragaria x ananassa*)

2011. godine, u časopisu *Environmental and Experimental Botany*, Grant i suradnici objavljuju svoj rad pod naslovom „Termografsko snimanje i sastav izotopa ugljika indiciraju razlike u provodnosti puči i iskoristivoj uporabi vode između sorti jagoda (*Fragaria x ananassa*)“.

U sklopu ovog istraživanja Grant i suradnici su u laboratorijskim uvjetima proveli termografsko snimanje i analizu izotopa ugljika da bi istražili koji je optimalan način za određivanje vodnih svojstava sorti jagoda. U ovom pregledu će biti opisan samo dio istraživanja koji se odnosi na termografsko snimanje, dok će analiza izotopa biti samo spomenuta po potrebi gdje se to odnosi na zaključke ili termografsko snimanje.

2.5.1. Uvod


Za dugoročnu održivost uzgoja potreban je razvoj sorti s većom učinkovitosti iskorištenja vode (eng. *water use efficiency*, WUE). Ona se može definirati agronomski kao omjer između uroda usjeva i utrošene vode, odnosno fiziološki kao omjer između fotosinteze i transpiracije. Visok WUE je s druge strane često povezan sa smanjenom provodljivosti puči (g_s), a koja za sobom povlači smanjen rast i urod. Optimalan usjev bi prema tome trebao imati i visok WUE i relativno visok g_s . U tom smislu je važno moći lako i brzo otkriti ta svojstva tijekom razvoja novih sorti.

Kada su puči na listu otvorene list se hladi transpiracijom, a kada su puči zatvorene transpiracija prestaje te se list ne može hladiti. Time se prirodno uspostavlja veza između g_s i temperature lista, odnosno krošnje. S obzirom na to, moguće je koristiti termografiju da bi se napravila selekcija poželjnih genetskih linija u ranoj fazi razvoja pojedinih biljaka. Termografija je već uspješno upotrebljena za identificiranje *Arabidopsis* mutacije koja sa sobom donosi promjenu u transpiraciji za određene koncentracije ugljikovog dioksida, relativnu vlažnost i sunčevo zračenje, no potencijal primjene na drugim sortama i usjevima nije dovoljno istražen. U sklopu ovog istraživanja se htjelo dokazati, pomoću termografije i analize izotopa ugljika, da postoji varijacija u fiziologiji lista između različitih sorti jagoda, a koja bi mogla pomoći u razvoju sorti jagoda s većim WUE.

2.5.2. Mjerenja

Termografsko snimanje je provedeno koristeći kameru ThermaCAM P25, tipa 234, proizvođača FLIR. Kamera je razlučivosti 320x240 piksela, ima fokalnu duljinu od 124 mm, te prostornu razlučivost 6,64°. Pri snimanju s udaljenosti od jednog i pol metra od lista vidno polje kamere je tada dimenzija 180 sa 130 mm. Za svaki niz mjerenja temperatura okoliša je određena mjerenjem temperature zgužvane aluminijske folije stavljene usporedo sa snimanim biljkama. Udaljenost kamere od lišća, temperatura zraka i relativna vlažnost su unošene u kameru prije svake serije mjerenja da bi se odmah kompenzirali utjecaji atmosfere.

Termografske snimke su napravljena na četiri dana tijekom ispitivanja u stakleniku. Prilikom snimanja su korištene drukčije metode snimanja da bi se mogli usporediti različiti pristupi snimanju. Tijekom prva tri dana biljke su bile stavljene u grupe od po pet biljaka i svaka grupa je snimana zajedno u jednoj snimci s ljestava. Prije snimanja je jedan list na svakoj od biljaka bio označen vrpcom. Taj list je morao biti potpuno razvijen i izložen, a identificirao se kasnije prema vrpki na digitalnoj fotografiji. Zadnjeg dana mjerenja biljke nisu pomicanje radi snimanja u grupama, nego su ostavljene na svojim mjestima na stolu i svaka biljka je zasebno snimana. Kamera je bila fokusirana na jedan list biljke i na udaljenosti od pola metra od tog lista. Slika 10 prikazuje digitalnu snimku i termogram na lokaciji.



Slika 10. Digitalna i termografska snimka jagoda tijekom mjerenja[6]

Tijekom prva dva dana snimanja listovi su bili pridržavani mrežom od strune da bi bili izravnani i okrenuti prema gore. Zadnja dva dana snimanja nije korištena mreža. Dvije biljke od pet koliko ih je bilo u grupama u prva tri dana snimanja su bile tamo kao referenca, od kojih je jedna prije snimanja špricana vodom da bi se puči potpuno otvorile, a druga premazana petrolejskim gelom da bi se puči potpuno zatvorile.

Temperatura u stakleniku je bila postavljena na 20 °C prvog i trećeg dana snimanja, odnosno na 25 °C drugog i četvrtog dana mjerenja. Snimanje je provođeno između 13 i 14 h (po lokalnom ljetnom vremenu). Temperatura zraka, relativna vlažnost zraka i fotosintetski aktivna radijacija na razini krošnje je bila bilježena svakih pola sata na lokaciji u sredini eksperimentalnog područja. Tijekom samog termografskog snimanja ove vrijednosti su bilježene svake minute. Vlažnost tla je mjerena tjedno u svakom loncu s jagodama. Provodljivost puči je mjerena porometrom.

2.5.3. Obrada podataka i rezultati

CWSI za obradu podataka je računat prema originalnoj formuli (4), a temperaturni indeks lista I_G je računat prema jednadžbi (9). Za procjenu provodnosti puči su korištena tri pristupa, pri čemu se pretpostavljalo da je otpor lista gubitku vode r_s dominantno uvjetovan upravo provodnošću puči. Taj otpor je zatim računat na tri načina. Prvi je kada se ne koristi referentna površina i dan je jednadžbom (15).

$$r_s = \frac{-\rho * c_p * r_{HR} * [s * (\vartheta_{leaf} - \vartheta_{air}) + D]}{\gamma * [(\vartheta_{leaf} - \vartheta_{air}) * \rho * c_p - r_{HR} * R_{ni}] - r_{aw}} \quad (15)$$

Drugi slučaj uzima u obzir samo suhu referentnu temperaturu prema jednadžbi (16):

$$r_s = \frac{-r_{HR} * [s * (\vartheta_{leaf} - \vartheta_{air}) + D]}{\gamma * (\vartheta_{leaf} - \vartheta_{dry}) - r_{aw}} \quad (16)$$

Treći slučaj uzima u obzir i suhu i vlažnu referentnu temperaturu, pa njegova jednadžba (17) glasi:

$$r_s = \left[0,5 * r_{aw} + \frac{s}{\gamma} * r_{HR} \right] * \frac{(\vartheta_{leaf} - \vartheta_{wet})}{(\vartheta_{dry} - \vartheta_{leaf})} + 0,5 * r_{aw} \quad (17)$$

Pri tome u trećem slučaju nisu potrebni podatci o relativnoj vlažnosti niti procjena upijene radijacije promatranog lista. U drugom slučaju se izbjegava samo procjena upijene radijacije, dok u prvom slučaju trebaju oba ta podatka. U sva tri slučaja je nužno poznavati temperaturu zraka i brzinu vjetra.

Prilikom analize nije pronađen značajna korelacija između temperature lista i navodnjavanja za slučaj kada su lončanice snimane pojedinačno, iako je postojala razlika između pojedinih sorti. Kada su biljke snimane u grupi, ali bez mreže, nije pronađen nikakav utjecaj navodnjavanja ili sorte na temperaturu lista, ni I_G , CWSI ili g_s procijenjene preko temperature lista. U slučaju kada je korištena mreža temperatura lista je bila značajno viša kod biljki koje su bile slabije navodnjavane ($p = 0,028$ i $p < 0.001$ za pojedina mjerenja). Pri tome je kod slabije navodnjavanih biljaka I_G bio manji, a CWSI viši. Također, temperaturni indeksi su bili međusobno slični prilikom snimanja na dva dana kada su temperature u stakleniku bile različite, neovisno od toga što su same temperature lista bile više onog dana kada je temperatura u stakleniku bila viša.

Primijećen je značajan utjecaj sorte na temperaturu lista u jednom mjerenju ($p = 0,024$) i na I_G u oba mjerenja ($p < 0,001$). Uz to je u jednom mjerenju primijećena međusobna veza između sorte i količine navodnjavanja ($p = 0,006$). Iako je bilo varijacija između vrijednosti I_G tijekom mjerenja, treba napomenuti da su sorte 'Elsanta' i 'Totem' imale niži I_G , a sorte 'Elvira', 'Florence' i 'Cambridge Favourite' su pokazivale viši I_G pri punom zalijevanju. Režim navodnjavanja i sorta su također utjecale na razliku između temperature lista i zraka, pri čemu su manje razlike zabilježene kod biljaka koje su bile smanjeno navodnjavane, sa sličnim rasporedom po sortama kao i kod I_G . Ovo nije bilo toliko značajno kao razlika u vrijednostima I_G za različite sorte, te prosječne vrijednosti nisu bile stabilne za dane kada temperatura u stakleniku nije bila jednaka.


Prilikom procjene vrijednosti g_s jednom od tri ranije navedene metode dobiveni su različiti rezultati. U prvom slučaju, kada se nije koristila referentna površina, rezultati nisu bili relevantni, te je nekoliko listova imalo veoma nerealne vrijednosti g_s . U trećem slučaju, gdje se koriste samo referentne temperature, također su se pojavile nerealne vrijednosti u par slučajeva. U drugom slučaju, gdje se u obzir uzima suha referentna temperatura i vlažnost zraka, rezultati su bili najbliži onim očekivanima i nisu imali nerealnih vrijednosti. Shodno tome ova metoda je odabrana za daljnju obradu podataka. Rezultati dobiveni ovom metodom su pokazali da g_s ima značajno niže vrijednosti u slabije navodnjavanim biljkama nego u dobro navodnjavanim

biljkama u slučaju kada je za snimanje korištena mreža da drži listove vodoravnima ($p < 0,001$).

Dodatno je primijećen značajan utjecaj sorte ($p = 0,01$ i $p = 0,001$).

Procijenjeni g_s je bio značajno niži kada je temperatura u stakleniku bila viša, no tada su i R_{ni} i D bili značajno viši. Kada prilikom snimanja nije korištena mreža za pridržavanje listova procijenjena vrijednost g_s nije pokazala značajnu razliku između režima navodnjavanja i sorti, što je bilo u skladu s dobivenim I_G za to mjerenje.

Uspoređivanjem termografskih mjerenja i mjerenja porometrom, dobiveno je da je prosječni izmjereni g_s za svaku sortu i režim navodnjavanja imao pozitivnu korelaciju s prosječnom vrijednosti I_G ($r = -0,788$ i $p \leq 0,001$), te negativnu korelaciju s prosječnom temperaturom lista ($r = -0,602$ i $p = 0,005$) i CWSIem ($r = -0,825$ i $p < 0,001$). Dobiveni rezultati se mogu vidjeti na slici 11.



Slika 11. Rezultati analize termografskog snimanja jagoda[6]

Provodljivost puči procijenjena na osnovu jednadžbe (16) je također bila u skladu s mjerenjima porometrom i iznosila u prosjeku 95% izmjerenih vrijednosti.

Zaključuje se da na temperaturu lista jagode utjecaj imaju njegov nagib i provodnost puči. U prirodnom položaju biljke nagib lista ima veći utjecaj na njegovu temperaturu nego provodnost puči, a osim toga nedostatak vode uzrokuje daljnju promjenu kuta lista. Stoga je potrebno prilikom snimanja u svrhu mjerenja g_s -a osigurati da su svi listovi jednake orijentacije. Kada se osigura ovaj preduvjet tada je mjerenjem nađena slična prosječna vrijednost I_G i CWSI za sve sorte pod istim režimom navodnjavanja čak i kad su mjerenja provođena u drugačijim meteorološkim uvjetima.

Ovo sugerira da su toplinski indeksi poput I_G i CWSI korisniji nego temperatura lista, razlika temperature lista i zraka ili čak i mjerenje g_s -a u slučajevima kada je ispitivanje potrebno vršiti kroz nekoliko dana. Takvi rezultati su u skladu s ranijim istraživanjima na jagodama od Lia i suradnika (2010.), te na drugim usjevima od Grant i suradnika (2007.), te Möllera i suradnika (2007.).

Osim ovoga, pronađena je i jasna veza između sorte jagode i I_G -a. Sve ovo upućuje na činjenicu da bi termografija trebala biti pouzdan alat za određivanje varijacija između sorti u daljnjem razvoju programa uzgoja novi sorti.

Ovdje nije korištena vlažna referentna površina, što je u skladu s ranijim istraživanjem Leinonen i suradnika (2006.) koji zagovaraju uporabu suhog referentnog lista. Time se postižu realistične procjene g_s tijekom obrade podataka, a izbjegava se potreba za visokom točnošću prilikom mjerenja temperature lista i potpuno uklanjanje potreba za mjerenjem sunčevog zračenja. Iako bi korištenje vlažne referentne površine pojednostavilo proces, u praksi se pokazalo da problemi u pravilnom održavanju WARSa mogu dovesti do značajnih varijacija u izmjerenoj temperaturi na njemu. Zbog toga je ranije navedena metoda bez vlažne referentne površine pouzdanija.

Za daljnje istraživanje predlaže se da se uzgoj biljaka jagode odmah napravi u grupama koje će se kasnije termografski snimati, te da se posude postave na pod i time izbjegne potreba za korištenjem ljestava da bi se mogli napraviti termografski snimci sa potrebne udaljenosti.

2.6. Procjena vodnog statusa korištenjem termografije: razvoj višegodišnjeg modela uz korištenje termografskih snimaka s tla

2014. godine, u časopisu Precision Agriculture, Cohen i suradnici objavljuju svoj rad pod naslovom „Procjena vodnog statusa korištenjem termografije: razvoj višegodišnjeg modela uz korištenje termografskih snimaka s tla“.

Ovo višegodišnje istraživanje se nastavlja na istraživanja koja su obrađena u dijelovima 2.1. i 2.3. I na ovom radu su surađivali iste institucije kao i na prošlom, te neke nove, tako da je on kolaboracija Volcani Centra iz Bet Dagona u Izraelu s Galilejskim centrom za tehnologiju iz Kiryat Shmona, Hebrejskim sveučilištem Jeruzalema, te Drom Yehuda udrugom poljoprivrednika iz Havat Shikmima.

2.6.1. Uvod


Iako su ranije studije ispitivale vezu između LWPa i CWSIa za veći broj usjeva ta veza je u pravilu bila modelirana prema podacima sa samo jednog dana mjerenja. Manji broj istraživanja je koristio mjerenja s par dana u tijeku sezone rasta, pa su primjerice Meron i O'Shaughnessy u svojim radovima pokazali da je ta veza relativno stabilna tijekom sezone. Jackson je u svojem radu 1991. pokazao da je ta veza različita za ranu i kasnu fazu rasta biljke, no da je stabilna u kasnoj fazi za biljke u različitim godinama.

Cilj ovog rada je bio definirati vezu između LWPa i CWSIa za pamuk na temelju visokorazlučivih termogramskih snimaka s tla, te proučiti postoji li robusna veza između tih odnosa za različite sorte i periode u rastu biljke, odnosno u različitim godišnjim dobima i geografskim i klimatološkim uvjetima.

2.6.2. Mjerenja

Termografsko snimanje je provedeno koristeći kamere SC2000 i PM545 proizvođača FLIR. Obje kamere su s mikrobolometarskim senzorom razlučivosti 320 x 240 piksela. Snimanje je obavljano s lećama od 24° i 45°. Kamere su bile postavljene na tronožac visine četiri metra, traktorsku dizalicu visine deset metara ili na kamionsku dizalicu visine 20 m.

Slika 12 prikazuje tri korištena načina postavljanja kamere.



Slika 12. Tri načina postavljanja kamere za mjerenja[7]

Kao referentna površina korištena je vlažna umjetna referentna površina (WARS) kao i u radovima od Merona i Alchanatisa. Tijekom mjerenja se pažljivo održavala vlažnost WARSa tako što se plutača potapala u vodu da bi se osigurala relevantnost mjerenja. Ovo je potrebno zato što kapilarni efekt omogućuje zadovoljavajuće samonavlaživanje samo u periodu od nekoliko minuta nakon inicijalnog ovlaživanja. Osim toga, važno je izravnati bilo kakve zračne mjehuriće koji mogu nastati na površini tijekom potapanja.

Inicijalna obrada termograma i fotografija je napravljena u Matlabu R13, a razvrstavanje osunčanih listova na temelju zasićenosti nijanse (eng. *hue-saturation-intensity*, HSI) je napravljeno u vlastitom softveru istraživačke grupe, a koji se zove Crosswise.

Sama mjerenja su provedena u ljeta 2003., 2005. i 2006. godine na pet polja koja se nalaze na tri geografski i klimatski različite lokacije u Izraelu. Sveukupno su mjerenja provedena na osamnaest zasebnih dana. Mjerenja su uglavnom provedena tijekom faze cvjetanja i faze dozrijevanja. Sva mjerenja su provedena sat ili dan prije idućeg navodnjavanja da bi se simulirala preporučena praksa uzimanja uzoraka LWPa prije navodnjavanja, tj. kada je vodni stres biljke maksimalan.

Na poljima je bio posađen pamuk u redovima razmaka 0,97 m, i gustoće 100 000 biljaka na hektar. Pojedino polje je bilo širine šest metara i duljine dvadeset metara, dok je navodnjavanje bilo s jednom cijevi na dva reda. Korišteno je više različitih režima navodnjavanja, od kojih su neki bili standardni, a drugi uskraćivali vodu biljci u određenim periodima. U nekim slučajevima se biljkama uskraćivalo navodnjavanje u odabranom periodu prije samog mjerenja, a uobičajeno ih se navodnjavalo u ostatku sezone.

LWP je mjereno na četiri najmlađa potpuno razvijena lista na svakom polju, a ti listovi su tijekom termografskog snimanja bili označeni aluminijskom oznakom da bi ih se moglo prepoznati na termogramu. Mjerenje LWPa je obavljeno tlačnom komorom u vrijeme solarnog zenita na lokaciji.

Od meteoroloških podataka mjereni su sunčevo zračenje, brzina vjetra, temperatura zraka i relativna vlažnost zraka, sve na visini od dva metra iznad tla. Mjerenja su obavljana pomoću pokretne meteorološke stanice uz jedno mjerenje svakih deset sekundi i uzimanje prosječne vrijednosti za svaku minutu. Na jednoj od lokacija nije bila dostupna pokretna meteorološka stanica, tako da su tu korišteni podatci s 2 km udaljene stanice u vlasništvu ministarstva poljoprivrede. Na njoj su podatci dani u prosječnim vrijednostima za desetominutne intervale.

2.6.3. Obrada podataka i rezultati

CWSI za obradu podataka je računat prema formuli (11) za koju se u ovom slučaju poziva na rad Jacksona i suradnika iz 1981. Kao i u ranijim radovima i ovdje su računate i teoretske i empirijske vrijednosti CWSIa, pri čemu su za teoretske vrijednosti korištene referentne temperature dobivene iz energetske bilanci lista prema Jonesu, a za empirijske vrijednosti su korištene izmjerena vrijednost sa WARSa za vlažnu referentnu temperaturu i temperatura zraka uvećana za pet stupnjeva za suhu referentnu temperaturu, prema Irmakovim opservacijama. U određenim slučajevima gdje razlučivost nije dopuštala upotrebu WARSa za određivanje vlažne referentne temperature korištena je metoda najniže temperature krošnje kao u ranijem radu Alchanatisa iz 2010.


Sveukupno je prikupljeno 488 parova mjerenja CWSI_{ARS}, CWSI_{I2} i LWPa. Za ukupni set podataka je linearna veza između CWSI_{ARS} i LWPa imala R^2 od 0,48, a veza između CWSI_{I2} i LWPa imala R^2 od 0,24. Daljnjom analizom je utvrđeno da podatci s četiri dana mjerenja nisu bili u skladu s očekivanom vezom između CWSIa i LWPa. Jedan od tih dana je bio u trenutku kada su biljke već bile poprskane sredstvom za defolijaciju i listovi su se počeli sušiti i otpadati na nekim poljima. Pretpostavka je da u takvim uvjetima zeleni listovi koji su odabrani za mjerenje LWPa nisu bili reprezentativni za cijelu krošnju. Sličnu pojavu je zabilježio Möller 2007. prilikom mjerenja u kasnom dijelu sezone u vinogradu.

Za dva dana je dobiveni CWSI točno opisivao koji dijelovi polja su bili smanjeno navodnjavani, no izmjereni LWP je sugerirao da su ta polja bila bez vodnog stresa. S obzirom

na to da nije zabilježen propust u rasporedu navodnjavanja, pretpostavlja se da je došlo do greške prilikom mjerenja LWPa.

Konačno, prilikom jednog od mjerenja su zabilježene veoma negativne vrijednosti CWSI_a, a razlog tome je što su zabilježene jako visoke temperature WARSa. Po njima je ispalo da je vlažna referentna temperatura par stupnjeva više od temperature okolnog zraka, dok je očekivana vrijednost niža od temperature okolnog zraka. Iz tog razloga se pretpostavlja da je WARS bio nepravilno postavljen ili vlažen tijekom ovog snimanja i podatci s ovog dana mjerenja su isključeni iz analize.

Nakon što je isključeno 168 mjernih točaka koje su prikupljene u ta četiri dana, i 6% podataka koji su značajno odstupali od ostatka, dobivena je dobra korelacija između CWSI_{ARS} i LWP, s R^2 od 0,68 i standardnom greškom od 0,26 MPa. S ukupno 324 promatranih točaka korelacija je značajna s $p < 0,001$. S druge strane CWSI_{I2} i LWP su imali nisku korelaciju s R^2 od samo 0,36. Neovisno do toga, u oba slučaja je nagib i pomak krivulje bio sličan. Slika 13. prikazuje vezu između CWSI_{ARS} i LWPa za sve mjerene podatke.



Slika 13. Veza između CWSI_{ARS} i LWP za mjerene podatke[7]

Ovi rezultati su u skladu s pronalascima Gonzaleza-Dugoa (2013.), Möllera (2007.) i O'Shaughnessya (2011.) na njihovim zasebnim istraživanjima koja su provedena na drugim usjevima. S druge strane, ovi rezultati su pokazali manji stupanj korelacije za pamuk nego je to bio slučaj u ranijim istraživanjima Jacksona (1991.), Merona (2010.) i O'Shaughnessya (2011.) gdje je R^2 bio između 0,82 i 0,90. No, te su studije obuhvaćale puno manji broj mjerenja i manje različite meteorološke uvjete na promatranim poljima.

Ipak, potrebno je posebno naglasiti razliku koja je dobivena u odnosu na Meronovu studiju iz 2010., a koja je prikazala značajno drugačiji nagib krivulje (-1,7 nasuprot -2,7) i


pomak (-1,2 nasuprot -0,61). Ta studija je proučavala jednu sortu tijekom jedne sezone rasta i prikupljala podatke u različitim intervalima prije i nakon navodnjavanja polja. Model predstavljen u ovoj studiji je pak uzimao u obzir dvije različite sorte kroz tri sezone rasta i podatke isključivo prije navodnjavanja.

Dobivena dobra korelacija između $CWSI_{ARS}$ i $LWPa$ služi kao indikator da je primjena procjene suhe referentne temperature kao temperature zraka uvećane za pet i vlažne temperature kao temperature umjetne referentne površine opravdana. Osim toga, najviša vrijednost $CWSIa$ koja je dobivena u studiji iznosi 0,92 što sugerira da i pri najvišim razinama vodnog stresa temperatura lista ne prelazi pretpostavljenu suhu referentnu temperaturu neovisno od drugih meteoroloških uvjeta. Sličan slučaj su u svojim istraživanjima imali i Meron (2010.) i O'Shaughnessy (2011.). S druge strane $CWSI_{I2}$ prema Jacksonu (1991.) koji koristi teoretske granice je dovodio do vrijednosti $CWSIa$ od čak 1,5. Meron (2010.) i O'Shaughnessy (2011.) u svojim istraživanjima nisu imali negativne vrijednosti $CWSIa$ prilikom korištenja $WARSa$, dok se u ovoj studiji u 7% slučajeva pojavila negativna vrijednost $CWSIa$ zbog temperature $WARSa$. Ova razlika se objašnjava time što su u ovoj studiji, za razliku od prethodnih, postojali dijelovi polja koji su bili prekomjerno navodnjavani.

S obzirom na to da se LWP kao mjera za regulaciju navodnjavanja koristi samo u fazi dozrijevanja, a u ranijim fazama se kao glavni indikator koristi visina biljke, tada su i podatci podijeljeni u dvije grupe po toj osnovi. Pronađena je značajna razlika između podataka u fazi cvjetanja i fazi dozrijevanja. U fazi cvjetanja nije pronađena korelacija između $CWSI_{I2}$ i $LWPa$, dok je u istoj fazi korelacija između $CWSI_{ARS}$ i LWP bila značajna, ali slaba ($R^2 = 0,46$ i $p < 0,05$). U fazi dozrijevanja je korelacija između $CWSI_{I2}$ i $LWPa$ bila slaba ($R^2 = 0,45$ i $p < 0,05$), dok je u istoj fazi korelacija između $CWSI_{ARS}$ i LWP bila veoma visoka i jasna ($R^2 = 0,82$). Osim toga, standardna greška je za fazu dozrijevanja kada se promatra posebno bila manja nego za set svih podataka i iznosila samo 0,22 MPa.

O'Shaughnessy je u svojoj studiji našao puno značajniju korelaciju u fazi cvjetanja (R^2 otprilike 0,80), a što je vjerojatno posljedica načina obrade termograma. U ovoj studiji je termogram računalno obrađivan da bi se razaznalo tlo od lišća, što je puno teži zadatak u fazi cvjetanja. O'Shaughnessy (2011.) je u svojoj studiji ovu obradu napravio ručno što je vjerojatno osiguralo da njegovi podatci budu puno pouzdaniji.


Razlika u modelu koji povezuje $CWSIa$ i $LWPa$ u fazama cvjetanja i dozrijevanja ukazuje na to da se ova veza vjerojatno mijenja u različitim fazama rasta biljke. Slika 14 prikazuje usporedno vrijednosti za fazu cvjetanja i fazu dozrijevanja.



Slika 14. Veza između $CWSI_{ARS}$ i LWP za različite faze rasta biljke[7]


To što je $CWSI_{I2}$ bio značajno lošiji u predviđanju LWP-a od $CWSI_{ARS}$ a ukazuje na to da su spoznaje o vezi vremenskih uvjeta i temperature lista nepotpune. U ovom radu je dalje istražen utjecaj vremenskih prilika na vezu $CWSI$ -LWP. Napravljena je regresijska analiza s više varijabli u kojoj se proučavao utjecaj temperature zraka, relativne vlažnosti zraka, sunčevog zračenja, brzine vjetra i $CWSI_a$ kao indikatora za predviđanje LWP-a. Pronađeni su značajni utjecaji temperature zraka, brzine vjetra i $CWSI_a$ na točnost predviđanja ($p < 0,05$). Unošenjem tih dodatnih varijabli se poboljšala korelacija između $CWSI_a$ i LWP-a. R^2 se u tom slučaju povećao sa 0,68 na 0,75, a standardna greška je pala sa 0,26 na 0,24 MPa. Kada se promatra po fazama razvoja, u fazi cvjetanja su relativna vlažnost zraka i sunčevo zračenje imali značajan efekt na LWP, ali njihovim uključivanjem u model nisu dobivena značajna poboljšanja modela. U fazi dozrijevanja je jedino $CWSI$ imao značajan učinak na predviđanje vrijednost LWP-a, što sugerira da je u ovoj fazi rasta veza između $CWSI_a$ i LWP-a stabilna u različitim vremenskim uvjetima.

Podjela usjeva na sorte je imala utjecaj na dobiveni odnos između $CWSI_a$ i LWP-a u analizi. Kada se promatra zasebno svaka od dvije korištene sorte (Akalpi i Pima), tada su obje imale drugačiji nagib i pomak krivulje nego jedinstveni model. Zanimljivo je da je unatoč tome model za specifičnu sortu pokazivao slabiju korelaciju nego zajednički model, tako da su oba zasebna modela imala R^2 od 0,70 i standardnu grešku od 0,26 MPa. Pretpostavlja se da je to posljedica toga da razlike među pojedinim sortama nisu veće nego razlike među pojedinim biljkama u miješanom uzorku. Rezultati ovog dijela analize su prikazani na slici 15.



Slika 15. Veza između $CWSI_{ARS}$ i LWP za različite sorte pamuka[7]

Model je uspješno prilagođen stvaranju karte LWPa na usjevu. LWPi su razdijeljeni u pet razreda, od kojih je svakom pridružena druga boja. Razredi su označavali različite razine vodnog stresa u biljci, a obrada je napravljena na temelju LWPa dobivenog preko $CWSI_{ARS}$. Dobivena karta LWPa je dobro odgovarala stvarnom stanju u polju, čime je pokazano da se predviđanje LWPa na temelju termogramskih snimaka može pouzdano i precizno koristiti na terenu. Slika 16 prikazuje dobivenu kartu LWPa. Rosenberg je u svojim istraživanjima paralelno s ovime pokazao primjer primjene infracrvene termografije iz zraka za upravljanje navodnjavanjem pamuka na komercijalnom usjevu.



Slika 16. Dobivena karta LWPa na osnovu termografskog snimanja[7]

2.7. Otkrivanje prostornih i vremenskih promjena u vodnom statusu vinove loze termografskim snimanjem

2016. godine, u časopisu *The Journal of Horticultural Science and Biotechnology*, Grant i suradnici objavljuju svoj rad pod naslovom „Otkrivanje prostornih i vremenskih promjena u vodnom statusu vinove loze termografskim snimanjem“.

Ovo višegodišnje istraživanje se nastavlja na istraživanje koje je obrađeno u dijelu 3.2. Dok su u prošlom radu istraživali značajne varijable prilikom snimanja, sada se korištenjem tih spoznaja provelo istraživanje na terenu. Rad je suradnja Sveučilišta Maynooth iz Kildarea u Irskoj sa Sveučilištem u Dublinu, te Instituta za znanosti o vinovoj lozi i vinu iz Logroña u Španjolskoj.

2.7.1. Uvod

U dosadašnjim istraživanjima korištene su razne referentne površine, no da bi termografija postala komercijalno primjenjiva metoda u upravljanju navodnjavanjem potrebno je provesti standardizaciju mjernih površina. Da bi mogle ući u široku upotrebu takve referentne površine morale bi biti jednostavne, jeftine i praktične, te se moći ili jednostavno pomicati od jedne biljke do druge ili lako replicirati na brojnim lokacijama unutar vinograda.

Termografske snimke iz zraka su problematične u vinogradarstvu jer je većina listova vinove loze orijentirana prema prolazima, a ne prema nebu. Upravo su listovi orijentirani u prolaze između redova istraživani u ranijim istraživanjima o nedostatku navodnjavanja kod vinove loze. Još uvijek nije dovoljno istraženo kakav je odnos temperature vrha trsa vinove loze i temperature većine listova koji su orijentirani prema prolazu između redova. U svojoj studiji u južnoj Australiji Loveys je 2008. našao da je temperatura vrha trsa vinove loze sorte 'Cabaret Sauvignon' povezana s temperaturom ostatka trsa, no viša.

Cilj ovog istraživanja je bio istražiti potencijal standardizirane, praktične i jeftine referentne površine, te istražiti da li je snimanje horizontalno orijentiranih listova s vrha trsa jednakovrijedno kao i snimanje vertikalno orijentiranih listova sa strane trsa.

2.7.2. Mjerenja

Termografsko snimanje je provedeno koristeći kameru ThermaCAM P640 proizvođača FLIR. Kamera je imala širokokutnu 45° leću, i razlučivost 640x480 piksela. Temperaturna razlučivost kamere je bila $0,06^\circ\text{C}$, a preciznost $\pm 2^\circ\text{C}$. Snimci su napravljeni s udaljenosti od 1,5 m od krošnje vinove loze, pri čemu je prostorna razlučivost bila otprilike 1 mm. Termografska kamera je istovremeno snimala i digitalne fotografije razlučivosti 2048x1536 piksela. Snimanje je provedeno na tri različita dana u rujnu 2010. godine. Zračenje okoliša je za svako snimanje procijenjeno kao prividna temperatura zgužvane aluminijske folije smještene na istu poziciju na kojoj se snimalo, uz emisivnost postavljenu na 1,00. Za mjerenja se, sukladno ranijem radu Jonesa (2004.), emisivnost na termografskoj kameri postavila na 0,96.

Trsovi su snimani sa strane, pri čemu je kameru držao termografist koji je stajao u prolazu pored biljke, odnosno odozgo, pri čemu je snimanje izvršeno sa strojnog berača grožđa s kamerom usmjerenom dolje prema vrhu trsa vinove loze. Snimke bočnog dijela trsova su napravljene ujutro 8h po sunčevom vremenu (10h po službenom lokalnom vremenu) i u popodne u 14h po sunčevom vremenu (16h po službenom lokalnom vremenu). Snimci vrhova trsova su napravljeni za vrijeme solarnog zenita u 12h po sunčevom vremenu (14h po službenom lokalnom vremenu).


Kao referentna površina korišten je komercijalno dostupan proizvod 'Evaposensor', proizvođača Sky Instruments iz Ujedinjenog kraljevstva, a koji je prikazan na slici 17.



Slika 17. Evaposensor, komercijalna referentna površina[8]

Ovaj proizvod se sastoji od dva umjetna lista na kutiji. Ovi 'listovi' su od platine premazane mat crnom bojom, duljine 50 mm, širine 10 mm i debljine 5 mm. Jedan od tih 'listova' je stalno održavan vlažnim kapilarnim efektom uz pomoć crne pamučne uzice koja je stalno upijala destiliranu vodu iz malog spremnika u kutiji. Unutar svakog od listova se nalazi termopar kojim je moguće očitati točnu temperaturu lista u pojedinom trenutku. Upotreba ovog senzora kao reference je potvrđena u radovima, Atkinsona (2003.), te Grant, Davies i Longbottoma (2009.). Rad od Harrison-Murray iz 1991. je potvrdio da ovakvi umjetni listovi vjerno imitiraju stvarne listove u njihovim temperaturnim odzivima na promjenu vanjskih vremenskih uvjeta.

Da bi se odredila emisivnost pojedinog umjetnog lista očitana je njegova temperatura izmjerena termoparom, te se mijenjala emisivnost na kameri dok se prikazana temperatura na kameri nije poklopila s onom izmjerenom na termoparu. Time je dobiveno da je emisivnost vlažnog lista 0,98, a emisivnost suhog lista 0,94. U kasnijim mjerenjima se temperatura listova mjerila pomoću termografske kamere uz korištenje ovih vrijednosti za emisivnost. Evaposensor je postavljen na posebno napravljeni nosač koji ga je orijentirao u istom smjeru kao i listove koji su snimani. Slika 18. prikazuje postavljanje i termografski snimak umjetnih listova.



Slika 18. Korištenje Evaposensora tijekom mjerenja[8]

Mjerenja su provedena 2010. godine na komercijalnom vinogradu u Tuelilli u La Rioji u Španjolskoj. Klima na lokaciji je mediteranska, a odabrana sorta je bila 'Tempranillo'. Mjerenja su napravljena na tri polja, od kojih je na jednom izvršena većina mjerenja, dok su na druga dva izvršena mjerenja za usporedbu pri drugačijim orijentacijama polja. Varijacije u navodnjavanju su bile u rasponu od standardnog navodnjavanja s 2 l/dan do dobrog navodnjavanja sa 6 l/dan. Treći set biljaka nije bio navodnjavaan. Navodnjavanje se vršilo kapanjem. Neki dijelovi polja su bili prirodno vlažan teren. Mjereni su provodljivost puči i vodni potencijal stabljike.

2.7.3. Obrada podataka i rezultati

CWSI za obradu podataka je računat prema formuli (11). I_G je u ovom slučaju računat malo izmijenjenom jednadžbom (8) u kojoj je temperatura lista zamijenjena temperaturom krošnje da bi se dobila jednadžba (18):

$$I_G = \frac{\vartheta_{dry} - \vartheta_{canopy}}{\vartheta_{leaf} - \vartheta_{wet}} \quad (18)$$

Osim mjerenjem suha i vlažna referentna temperatura računate su i teorijskim izrazima. Suha referentna temperatura dana je jednadžbom (19).

$$\vartheta_{dry} = \vartheta_{air} + \frac{r_{HR} * R_{ni}}{\rho * c_p} \quad (19)$$

Teorijska vlažna referentna temperatura računata je izrazom (20):

$$\vartheta_{wet} = \vartheta_{air} + \frac{\gamma * r_{HR} * r_{aW}}{\rho * c_p * (S * r_{HR} + \gamma * r_{aW})} * R_{ni} - \frac{r_{HR}}{S * r_{HR} + \gamma * r_{aW}} * D \quad (20)$$

S obzirom na to da je snimanje uvijek obavljano za sunčanih dana pretpostavila se temperatura zračenja neba na 20 °C niže od temperature zraka. Drugi empirijski koeficijenti i pojednostavljenja korištena u ovoj jednadžbi su upotrebljeni u skladu s ranijim istraživanjima. Brzina vjetra mjerena anemometrom na dva metra visine je, prema Leinonenovim istraživanjima, prevelika u odnosu na stvarnu brzinu na razini krošnje, te se za nju sukladno njegovom radu koristi koeficijent od 0,55.

Upotrebljeni različiti režimi navodnjavanja su u pravilu imali željeni učinak na stvaranje varijacija u provodljivosti puči, iako su na jednom od pomoćnih polja sve biljke imale visok g_s i Ψ_{stem} . U jednom od mjerenja na glavnom polju temperature okomitih listova na bočnim stranama trsova i horizontalnih listova na vrhu trsova su imale značajnu inverznu korelaciju s g_s . Korištenjem ARSa za računanje toplinskih indeksa, pronađena je značajna korelacija I_G s g_s , te je CWSI bio u značajnoj inverznoj korelaciji sa Ψ_{stem} . Pri čemu je Ψ_{stem} veličina analogna LWPu, samo što se mjerenje ne radi na listu nego na stabljici biljke. Ipak, uz izuzetak CWSIa za bočnu stranu trsova, ova korelacija nije bila značajnija od korelacije između same temperature i navedenih vrijednosti.

U drugim mjerenjima je u nekim slučajevima pronađena korelacija, a u drugima korelacija uopće nije pronađena. U slučajevima kada nije pronađena nikakva korelacija je relativna vlažnost bila visoka i sunčevo zračenje nisko, ali je isto tako u sličnim uvjetima prilikom drugog mjerenja pronađena jasna korelacija.

Kada su referentne temperature računate iz teorijskih izraza, tada je korelacija, na mjerenjima gdje je postojala, bila malo slabija za mjerenja na bočnoj strani trsova. No, s druge strane je korištenjem teorijskih izraza dobivena nešto bolja korelacija toplinskih indeksa i fizioloških veličina za mjerenja vrha trsova. Kao ni kod empirijskih izraza, ovo nije vrijedilo za rezultate sa svih dana mjerenja. Tako je u nekim danima korelacija bila značajnija korištenjem teorijskih izraza, a u drugima slabija. Također, u slučajevima kada nije pronađena korelacija korištenjem empirijskih vrijednosti, korelacija nije pronađena ni korištenjem teorijskih izraza.

U slučajevima kada je pronađena korelacija toplinskih i fizioloških varijabli, ona je bila različita za podatke s bočne strane i podatke s vrha krošnje. Nagibi i pomaci krivulje su bili različiti za sve setove podataka, a razlikovali su se čak i za mjerenja na listovima iste orijentacije.

U zaključku se navodi da je temperatura krošnje previše nestabilna za kvalitetnu analizu, te da je za određivanje vremena, no ne i mjesta, navodnjavanja bolja opcija korištenje toplinskih indeksa. Osim toga, nađene korelacije su u pravilu bile značajnije za toplinske indekse nego za same temperature. Nedostatak korelacije između temperature i fizioloških varijabli u nekim mjerenjima dodatno govori u korist upotrebe ARSa radi određivanja toplinskih indeksa.

Kao što su našli i Jones (2009.), Maes i Steppe (2012.), potencijal termografije da razlikuje između listova s višim ili nižim g_s je veći u slučaju kada su sunčevo zračenje i temperatura zraka viši, a relativna vlažnost niža. Također, u ovoj studiji je korišten manji vodni stres biljaka pri ispitivanju, što vjerojatno objašnjava činjenicu da su pronađene manje korelacije nego u prethodnim ispitivanjima gdje je vodni stres pri mjerenju bio veći.

Što se tiče upotrebe Evaposensora, on je pouzdano radio, no temperature očitane s njegove površine u pravilu nisu davale bolju značajnu korelaciju od korištenja teorijskih izraza. Predlaže se da oblik umjetnih listova treba bolje aproksimirati oblik lista biljke.

Snimke gornjih dijelova trsova su davale drukčije korelacije nego snimke bočnih strana, no u pravilu su točno predviđale vodni stres biljke.

3. ANALIZA KORIŠTENIH METODA

U prethodnom je poglavlju prikazan pregled nekih od značajnijih istraživanja u polju primjene infracrvene termografije u poljoprivredi. U ovom poglavlju će biti napravljena zajednička analiza tih radova. U ovoj analizi se želi raspraviti koji su pristupi i metode zanimljivi za daljnje istraživanje, kako u laboratoriju tako i na terenu, u kontekstu primjene u Republici Hrvatskoj. Također, želi se pronaći i identificirati nedostatke i prednosti u tim metodama, a koji bi zatim mogli biti ispravljeni, odnosno primijenjeni, u budućem istraživanju.

3.1. Analiza metoda termografskog snimanja

U kontekstu primijenjene infracrvene termografije je po svojoj prirodi najočitiiji dio za analizu u prethodnim radovima upravo metoda termografskog snimanja. Sam proces snimanja, tj. podatci prikupljeni tijekom snimanja, su glavni i definirajući faktor u relevantnosti daljnje analize i istraživanja. U dosadašnjim radovima se mogu primijetiti određene sličnosti u metodama snimanja, koje su dijelom posljedica same tehnologije, a dijelom specifičnih potreba u poljoprivredi. Pregled glavnih razlika između pojedinih radova, pa i u samim radovima, dan je u tablici 1.

U nekima od obrađenih radova nisu zapisani svi podatci koji su uspoređivani, te je u tom slučaju ostavljena neispunjena odgovarajuća ćelija. Radovi su u tablici identificirani brojem potpoglavlja u kojem su obrađeni u prethodnom poglavlju. Neki su radovi koristili više različitih kamera ili više različitih metoda snimanja, pa se oni shodno tome i pojavljuju više puta u tablici.

U većini mjerenja su neke od postavki bile jednake ili slične. Tako su primjerice sva mjerenja osim najstarijeg i najnovijeg mjerenja od Grant [3] [8] provedena kamerama s razlučivosti 320x240 piksela. Grant u svom najstarijem radu koristi kameru manje razlučivosti 120x120, dok u najnovijem radu koristi kameru veće razlučivosti 640x480. Ovo je u skladu s nekakvim utvrđenim standardima za znanstvena istraživanja, te se može zaključiti da je korištenje kamere rezolucije 320x240, ako ne minimum, onda barem standard za sva daljnja istraživanja.

Tablica 1. Usporedba termografskih postavki raznih autora

Oz. Rada (-)	Kamera (-)	Leća (°)	Razlučivost (px x px)	Udaljenost (m)	Kut (°)	Prost. raz. (mm)	Temp. raz. (°C)	Ref. površ. (-)
2.1.	FLIR PM545	24°	320x240	4	0°	5	0,10	ARS
2.2.	IRS 525		120x120	1,5	0°	17	0,10	(Ne)navodnjav. krošnje
2.2.	IRS 525		120x120	0,9	0°	2,4	0,10	Vlaženi/gelirani listovi
2.3.	FLIR PM545	24°	320x240	4	0°	5	0,10	ARS
2.3.	FLIR PM545	45°	320x240	19	60°	5	0,10	Najniža temperatura krošnje
2.4.	FLIR SC2000	45°	320x240	4	0°			ARS -ind.
2.4.	FLIR SC2000	45°	320x240	49	0°			ARS -ind.
2.5.	FLIR P25-234	24°	320x240	1,5	0°			Vlaženi/gelirani listovi
2.6.	FLIR PM545	24°	320x240	3	0°	5	0,10	ARS
2.6.	FLIR PM545	24°	320x240	9	0°	5	0,10	ARS
2.6.	FLIR SC2000	45°	320x240	19	0°	5	0,10	ARS
2.7.	FLIR P640	45°	640x480	1,5	0°	1	0,06	ARS -evapo.

Situacija je relativno jednolična što se tiče i drugih osnovnih postavki, pa se i kod leća koje se koriste za snimanje jasno pokazalo, opet uz izuzetak zadnjeg istraživanja od Grant [8], da istraživači u pravilu koriste leće od 24° širine vidnog polja za snimanje s relativno malih udaljenosti, dok se za veće udaljenosti koristi širokokutna leća od 45° . Pri tome se može zaključiti da je granica između kratkih i dugih udaljenosti snimanja pri redu veličine od 10 metara. Iako su se za neka snimanja na udaljenosti manjoj od 10 metara koristile i leće od 45° , ni u jednom mjerenju za snimke s udaljenosti veće od 10 metara nije korištena kamera od 24° .

Prostorna razlučivost je pokazala relativnu jednoličnost u određenim snimanjima. Tako su u većini slučajeva autori namještali prostornu razlučivost tako da jedan piksel na termogramu odgovara području širine 5 mm na promatranom objektu. Jasno je da je pri zračnim snimanjima, i snimanjima s dizalice prostorna razlučivost bila najniža, te Meron [5] u radu u dijelu 3.4. ukazuje da je granica prostorne razlučivosti ona prostorna razlučivost kod koje je još moguće razaznati krošnje od okolnog tla, a što je slučaj kada je mjerna točka najviše jednaka polovici širine reda usjeva. U bližim snimanjima se s druge strane postizala znatno veća prostorna razlučivost, a samim time se omogućila i analiza na razini lista, a ne samo krošnje kao cjeline.

Kut snimanja koji je korišten je posebno zanimljiv za analizu. Zbog same tehnologije termografskog snimanja idealan kut snimanja je okomit na promatrani objekt, no u poljoprivrednoj primjeni je okomito snimanje neučinkovito za snimanje velikih površina polja. Ovo se donekle može riješiti korištenjem bespilotnih letjelica ili zrakoplova, o čemu će još biti riječi, ali tada se javljaju drugi problemi. Pri snimanju s tla trenutno ne postoji jasno istražen optimum kuta snimanja. Većina obrađenih radova je koristila okomito usmjerenu kameru, no primjerice Alchanatis i Cohen u svojim radovima daju i primjer s kamerom pod kutom koja snima cijelo polje, te su te snimke uspješno primijenjene za izradu karte LWPa veće površine. Po pitanju praktične primjene je upravo snimanje pod kutom ono koje može u kratkom roku biti najpovoljnije rješenje za široku primjenu, jer bi moglo koristiti fiksnu kameru koja snima cijelo polje, te ne bi zahtijevalo dodatnu edukaciju i investiciju koju predstavlja nabavka bespilotne letjelice. Unatoč tome, okomite snimke su u pravilu korištene za razvoj samih modela kojima se povezuju izmjerene vrijednosti temperature i LWPa usjeva. U sklopu budućih istraživanja bi bilo zanimljivo provesti usporedbu pouzdanosti predviđanja LWPa na osnovu okomitih snimaka i onih pod kutom.

Temperaturna razlučivost kamere nije predstavljala ograničenje u istraživanju u obrađenim radovima. Autori su u svim slučajevima, osim opet u najnovijem istraživanju od Grant [8], koristili kamere s temperaturnom razlučivošću od $0,1^\circ\text{C}$. S obzirom na to da

korištene histogramске metode koriste temperaturene razrede istog reda veličine, te da razlike temperatura koje se promatraju u pravilu nisu manje od toga, tada se može zaključiti da je ta temperaturna razlučivost u potpunosti zadovoljavajuća za analizu vodnog potencijala lista i vodnog stresa usjeva.

Konačno, potrebno je reći nešto i o primjeni zrakoplova i bespilotnih letjelica u termografskom snimanju u poljoprivredi. Iako takav način snimanja omogućava pokrivanje velikih površina u kratkom roku, on trenutno ima određena tehnološka ograničenja koja sprječavaju širu primjenu. Prvenstveno je tu riječ o brzini snimanja, pri čemu standardne kamere sa mikrobolometarskim osjetnicima nemaju dovoljno veliku brzinu osvježavanja slike da bi mogle snimiti kvalitetne snimke pri uobičajenim brzinama leta. To dovodi do razmazivanja piksela, pri čemu su dobiveni pikseli na termogramu zamućeni i mjerna površina koju pojedini pikseli obuhvaćaju nije jednolikih dimenzija. Problem mutnih termograma se donekle može riješiti softverskom analizom, ali u tim slučajevima se nužno gubi na preciznosti samog mjerenja korištenjem fiksnih kompenzacija. Izgledno je da će se u budućnosti ovaj problem riješiti razvojem kamera s većom brzinom akvizicije slike, no trenutno se jedino može smanjiti brzina leta, čime se ujedno smanjuje i glavna prednost ove metode.

3.1.1. Uvod

Uza sve ranije navedeno, u specifičnom polju primjene infracrvene termografije za određivanje vodnog stresa usjeva, možda najznačajniji problem je određivanje referentnih temperatura za izračun CWSIa, tj. određivanje odgovarajućih referentnih površina za korištenje tijekom samog termografskog snimanja. U obrađenim radovima se najveća razlika u metodologiji mjerenja uočava upravo u polju referentnih površina, te se koriste različite površine i izvode međusobno ponekad i suprotni zaključci o praktičnosti i korisnosti pojedinih vrsta referentnih površina.

Prije uporabe termografije referentna temperatura se određivala iz teorijskih izraza temeljenih na energetske bilanci lista prema Jonesu i Jacksonu (1991.). Vrijednosti dobivene ovim izrazima su u nekima od obrađenih radova uspoređivane s mjerenim vrijednostima, te su uglavnom mjerene vrijednosti pokazivale bolje korelacije. Ipak, u određenom broju slučajeva su se i ove teorijske vrijednosti pokazale boljima, tako da one i dalje ostaju osnova s kojom se uspoređuju svi empirijski dobiveni rezultati. Pri tome treba napomenuti da se većina razmatranja odnosi na vlažnu referentnu temperaturu, jer se suha referentna temperatura u

velikom broju slučajeva, kako je i pokazano u obrađenim radovima, može točno aproksimirati kao temperatura zraka uvećana za pet stupnjeva.

Najjednostavnija metoda određivanja vlažne referentne temperature je korištenje najniže zabilježene temperature krošnje na termografskom snimku. Ova metoda ima prednost u tome što osigurava da se ne mogu pojaviti negativne vrijednosti CWSIa obzirom da ne postoji mogućnost da temperatura bilo kojeg dijela krošnje bude niža od odabrane vlažne referentne temperature. Problem s ovim pristupom je što tako određena vlažna referentna temperatura može biti značajno viša od stvarne, a što može značiti da veza između CWSIa i LWPa za takav slučaj neće biti relevantna u drugim uvjetima.

Unaprijeđena inačica prethodne metode koristi posebno pripremljene dijelove polja na kojima je korišten režim navodnjavanja koji osigurava da listovi tih biljaka imaju sasvim otvorene puči i temperaturu što bližu vlažnoj referentnoj temperaturi, odnosno suhoj referentnoj temperaturi ako se i ona mjeri. U istraživanjima je ova metoda polučila dobre rezultate, te su također u pravilu izbjegnute negativne vrijednosti CWSIa. U smislu praktičnosti za snimanje ona je usporediva s prethodnom, no znatno je teža za održavanje jer se na tom dijelu polja mora paziti da se dostatno ili čak i nešto više navodnjavaju usjevi. Taj problem je još veći za suhu referentnu temperaturu jer je postići točnu razinu vodnog stresa koja će omogućiti dobro očitavanje temperature, a da biljka u isto vrijeme može nastaviti rasti, je prilično težak zadatak.

Prethodne dvije metode su ujedno jedine izravne metode koje se mogu koristiti za snimanje velikih površina, obzirom da sve druge metode uključuju referentne površine koje se ne mogu razaznati pri prostornoj razlučivosti dostupnoj kod takve vrste snimanja.

Posljednja metoda koja koristi samu biljku za mjerenje, i koja se primarno koristi kod snimanja iz veće blizine, je metoda korištenja pripremljenih listova kao referentnih površina. Ovaj pristup koristi Grant [3] u svom prvom radu, gdje vlaži listove prije snimanja da bi dobila vlažnu referentnu površinu, odnosno premazuje ih petrolejskim gelom da bi im prisilno zatvorila puči i dobila suhu referentnu površinu. Iako pouzdana, ova metoda je veoma ograničena u upotrebi jer zahtjeva da se pojedini listovi ručno pripreme, a i pojedini listovi u pravilu nisu vidljivi kod snimaka većih sekcija polja.

S obzirom na gore navedeno, istraživači su također pokušali koristiti više verzija umjetnih referentnih površina da bi njima olakšali mjerenja i uklonili potrebu za pripremom bilo pojedinih sekcija polja ili listova za mjerenje referentnih temperatura.

Svi korišteni ARSovi su u pravilu bili površine koje imitiraju list po svojstvima emisivnosti, a kojima je temperatura definirana ishlapljivanjem vode s njihove površine. Tu se

ističu dva pristupa, Meronov [5] koji koristi slobodno plutajuću površinu da bi simulirao samo vlažnu referentnu površinu i Grantin [8] pristup koji koristi fiksne umjetne listove od kojih je samo jedan vlažan, te time simulira i suhu i vlažnu referentnu površinu. Povrh toga, u nekim svojim mjerenjima Meron [5] koristi ARS kao neizravnu referentnu površinu, te ju ne snima na istoj snimci kao i promatranu sekciju polja. U tom smislu u tablici 1. se razlikuju „ARS“, čime su označene izravno mjerene referentne površine kao u Meronovim radovima, „ARS – ind.“ čime su označene referentne površine kao u Meronovim radovima, ali koje su mjerene nezavisno od termograma polja, te „ARS – evapo.“ čime je označeno korištenje komercijalnog ARSa s umjetnim listovima pod nazivom „Evaposensor“ kao u radu od Grant.

Meronov pristup tu možda zaslužuje najdetaljniju analizu jer je korišten u najvećem broju ispitivanja, te dao najrazličitije rezultate. U situacijama kada je ARS pravilno održavan vlažnim i sniman postavljen u krošnji biljke, dobivena je pouzdana vrijednost vlažne referentne temperature na osnovu koje su računati iznosi CWSIa s visokom korelacijom s LWPom. Ovo je bio slučaj u istraživanjima i Cohena [2] i Alchanatisa [4] i Merona [5]. Korištenjem plutajuće površine osiguravala se okomitost, a uranjanjem površine se osiguravalo da je uvijek pravilno navlažena. Ipak, u nekolicini mjerenja, pogotovo u onima gdje se neizravno mjerila temperatura ARSa je došlo do situacije da su mjerene temperature krošnje ili listova bile niže od izmjerene vlažne referentne temperature, a u jednom danu mjerenja su čak rezultati morali biti u potpunosti odbačeni jer su vrijednosti izmjerene na ARSu bile fizikalno besmislene u usporedbi s temperaturom zraka.

Grant [8], s druge strane, u istraživanju u potpoglavlju 2.7. gdje koristi Evaposensor, ne nailazi na probleme s pouzdanošću referentne površine, no ima problema s njenom veličinom. Evaposensor je naime značajno manje površine od Meronovog [5] ARSa, a osim toga mu je i orijentacija ovisila o tome koliko spretno su ga pričvrstili u krošnji prije mjerenja. Samim time je njegovo korištenje ograničeno na snimke iz velike blizine, a to istraživanje i je koristilo jednu od najbližih udaljenosti snimanja od svih promatranih. Ovdje valja spomenuti da se Grant [6] u svom ranijem radu osvrće na problem upotrebe ARS-a i po uzoru na Leinonen (2006.) predlaže uporabu teorijskih izraza uz korištenje izmjerene samo suhe referentne temperature, upravo da bi se izbjeglo korištenje ARSa za mjerenje vlažne referentne temperature i s tim povezanih problema s pouzdanošću izmjerenih podataka.

U zaključku bi trebalo napomenuti da iako korištenje ARSa sa sobom donosi potencijal za grešku prilikom mjerenja, u većini ispitivanja do sada se pokazalo da daje pouzdanije rezultate od čisto teorijskih izračuna ili mjerenja posebno pripremljenih listova. S praktične

strane ono je puno jednostavnije od pripreme listova, a i ne unosi se dodatna nesigurnost u mjerenje potencijalno lošim odabirom referentnih listova za obradu. Glavni nedostatak korištenja ARSa je njihova veličina, potreba za održavanjem i relativno ograničena mobilnost, čime se isključuje njihova upotreba na velikim komercijalnim plantažama i pri snimanju iz zraka. S druge strane korištenje krošnji, bilo posebno pripremljene sekcije polja ili samo najniže zabilježene temperature, ima najveći potencijal za široku upotrebu pod uvjetom da se mogu u modelu pravilno predvidjeti potencijalna odstupanja koja mogu nastati zbog nedovoljnog održavanja posebno pripremljene sekcije ili relativno visoke razlike temperatura između najhladnije krošnje i stvarne vlažne referentne temperature.

Za laboratorijska mjerenja, koja su ionako po svojoj prirodi ograničena na manje udaljenosti snimanja, optimalno bi bilo koristiti ARS barem kao referencu s kojom se mogu usporediti temperature krošnji promatrane biljke. U tom smislu bi bilo zanimljivo istražiti kolika je razlika u temperaturi između ARS-a i posebno pripremljene krošnje ili lista da bi se mogle kalibrirati temperature izmjerene na ARSu i tako uzeti u obzir da ARS nije savršena imitacija lista.

3.2. Analiza metoda obrade podataka

Metoda obrade podataka kod novih tehnologija je možda i najvažniji dio nekog znanstvenog rada. Ovo je posebice slučaj kada ne postoji nedvosmislena teorijska podloga koju se eksperimentalno nastoji potvrditi, nego se pokušava pronaći empirijska veza između dviju ili više promatranih veličina. Određivanje utjecajnih varijabli, opravdanih pretpostavki i konačnog načina analize može znatno utjecati na vjerodostojnost pronalaska, odnosno na to hoće li se moći pronaći značajna korelacija na osnovu koje bi se mogao napraviti model za uporabu u drugim slučajevima.

Svi obrađeni radovi su teorijsku podlogu našli u ranijim radovima Idsa (1981.), Jonesa (1991.) i Jacksona (1981.) koji su uveli pojam indeksa vodnog stresa usjeva tj. CWSIa kao bezdimenzijske značajke koja je u izravnoj vezi sa LWPom biljke.

CWSI je kao značajka definiran temperaturama i fizikalno predstavlja, u formulacijama kao (4) i (11), relativnu nadtemperaturu biljke iznad temperature koju bi imala da je optimalno navodnjavana i potpuno otvorenih puči (vlažne referentne temperature), a sve to dodatno u odnosu na neku najvišu temperaturu koju bi mogla poprimiti kada bi postojao potpuni izostanak opskrbljenosti biljke vodom tj. potpuno zatvorene puči (suhe referentne temperature). U tom

smislu CWSI je indikator koliko je temperatura bilo lista ili krošnje daleko od bilo kojeg od ta dva ekstrema, pri čemu bi s idealnim izborom svih triju relevantnih temperatura vrijednost CWSIa bila između 0 i 1. U praksi je zbog ograničenja mjerenja raspravljenih u prethodnom potpoglavlju, teško mjerenjem odrediti referentne temperature, pogotovo vlažnu referentnu temperaturu, s visokom točnošću, tada postoji mogućnost da vrijednost CWSIa bude i veća od 1 i manja od 0.

U provedenim istraživanjima je pretpostavljena i statističkom analizom u većini slučajeva potvrđena značajna inverzna linearna korelacija između mjerenih vrijednosti LWPa i CWSIa. Iako oblikom stabilna, ta veza je između različitih istraživanja pokazivala veliku oscilaciju u vrijednostima nagiba i pomaka krivulje. Ta razlika se pokazala za različite geografske i meteorološke uvjete, za različite stadije razvoja biljke, i za različite vrste usjeva. Ipak, pronađena je značajna ponovljivost za isti usjev u istom stadiju razvoja i u istim geografskim i meteorološkim uvjetima. Ovo ukazuje na to da će vjerojatno biti potrebno razviti empirijske modele za pojedine usjeve i meteorološke zone, no da bi se kada se oni razvijaju mogli s dobrom pouzdanošću koristiti u svim slučajevima u kojima su te iste pretpostavke ispunjene.

Analogno CWSI-u je definirana i značajka I_G , dana jednadžbom (8), koju u svojim radovima koristi Grant. Iako oblikom i ulaznim veličinama slična CWSIu, značajka I_G je postavljena tako da bude linearno proporcionalna provodljivosti puči g_s . Ona predstavlja omjer razlika temperature lista do suhe i vlažne referentne temperature, te je zbog toga iz nje teže iščitati relativne vrijednosti temperatura koje je čine. Negativna vrijednost I_G tako može predstavljati i prenisku suhu referentnu temperaturu i previsoku vlažnu referentnu temperaturu. To je čini manje praktičnom od CWSIa za brzu procjenu podataka na terenu. Ipak, u istraživanju su dobivene značajne korelacije između ove vrijednosti i provodljivosti puči, pa je samim time ona prihvatljiv način promatranja veze fizioloških reakcija biljke pri različitim temperaturama i režimima navodnjavanja. No, u daljnjoj analizi bi radi standardizacije podataka i praktičnosti u uporabi ipak bilo poželjno istraživanje temeljiti prvenstveno na CWSIu.

Naravno, za dobivanje gore navedenih značajki potrebno je napraviti obradu termograma, a u obrađenim radovima se to u pravilu radilo histogramski i u dva koraka. Prvo je na termogramu ručno ili nekim algoritmom odbačen dio piksela na kojima nije bila prikazana krošnja, odnosno list, te su u obradu ulazili samo oni pikseli koji bi prošli ovu selekciju. Ovdje su bile moguće i događale su se greške, te je tako izgledno da većina mjerenja obavljanih u ranijim fazama rasta biljke sadrži u analizi i određen broj piksela koji zapravo prikazuju tlo. Ovo je posljedica toga što se ti pikseli „skrivaju“ između piksela lišća na nepotpunoj krošnji

biljke koja je još u rastu i listanju, te ih je u automatskim metodama selekcije teško identificirati. Unatoč tom nedostatku automatska analiza, pogotovo odbacivanjem temperatura izvan određenog raspona ili namjenskim softverom, se pokazala dovoljno pouzdanom za uporabu. Povrh toga ona značajno smanjuje radne sate i ljudski rad potrebne za obradu pojedinog termograma, te je stoga preduvjet uspješne automatizacije metode.

Drugi korak je podjela odabranih piksela u razrede. U pravilu su korišteni razredi koji su odgovarali temperaturnoj razlučivosti kamere od 0,1 °C. Cohen [2] u svom istraživanju u potpoglavlju 2.1., koje je prvo od obrađenih koje koristi taj pristup, izravno koristi skalu s nijansama sive termograma da bi napravio histogramsku podjelu podataka pri čemu svaka od 255 dostupnih nijansi sive odgovara upravo jednom histogramskom razredu temperature. Meron [5] kombinacijom te metode i odbacivanja histogramskih razreda izvan zadanog temperaturnog raspona dodatno pospješuje brzinu obrade termograma, a zadržava zadovoljavajuću kvalitetu rezultata čemu svjedoče dobiveni rezultati njegovog istraživanja.

U daljnjem praktičnom razvoju metode primjena Meronovog [5] pristupa analizi termograma će vjerojatno postati standard, pri čemu bi se u daljnjem istraživanju trebalo detaljnije istražiti način određivanja granica temperaturnog razreda koji se uzima u obzir za daljnju analizu. Ipak, u laboratorijskom radu gdje se zahtjeva visoka preciznost i točnost, a broj snimaka i uzoraka je relativno malen, ručna analiza termograma je i dalje nužna ako se želi ukloniti što više potencijalnih izvora nesigurnosti u analizi. Potencijalno bi zanimljiva bila analiza razlika u dobivenim histogramima nakon strojne obrade po Meronu i ručne analize, a takva usporedba bi nedvojbeno dala daljnji uvid i u opravdanost njegova izbora granica promatranog temperaturnog raspona. Osim toga, mogla bi se provesti i analiza očekivanih temperatura tla ispod krošnji i između redova, čime bi se dodatno moglo potvrditi ili prilagoditi temperaturni raspon za koji se s pouzdanošću može tvrditi da pripada upravo lišću, odnosno krošnji usjeva.

3.3. Analiza rezultata

U obrađenim radovima je prikazan veći broj empirijski dobivenih krivulja i veza između CWSIa i LWPa, odnosno I_{Ga} i g_{sa} . One nisu sve međusobno usporedive, jer se uspoređivati smiju samo mjerenja na istim vrstama usjeva, no ne nužno i istoj sorti. Primjerice kod pamuka, Cohen [7] u svojem radu opisanom u potpoglavlju 2.6. nalazi da je korelacija ukupnog modela veća kada se zajedno promatraju obje sorte pamuka (*Akalpi* i *Pima*), dok je za svaku od njih

pojedinačno korelacija niža. Ovo se objašnjava time što je razlika između sorti malena. S druge strane, Grant [6] u svojem radu nalazi jasne razlike između sorti jagoda pri prirodnoj orijentaciji listova, no njenom istraživanju u fokusu i jest bio upravo pronalazak takvih razlika, te su namjerno koristili međusobno različite sorte da bi mogli pravilno kalibrirati model. Iz gore navedenog se može zaključiti da modeli koji opisuju ponašanje više sorti jedne vrste biljaka jesu mogući, no da je potrebno zasebno istražiti svaku sortu da bi se mogla procijeniti opravdanost takvog pristupa.

Istraživanja izraelskih znanstvenika su tu posebno zanimljiva jer u njima postoji međusobna sljedivost u jednom duljem periodu, te treba primijetiti da iako su oni koristili slične metode nisu dobivali jednake veze između CWSIa i LWPa. Štoviše, u nekim slučajevima, su nađene značajne razlike na istoj vrsti usjeva. Cohenova [7] višegodišnja studija tako pokazuje značajnu razliku u odnosu na Meronova istraživanja, i manji stupanj korelacije nego što su našli Jackson (1991.), Meron (2010.) i O'Shaughnessy (2011.) u svojim istraživanjima. Povrh toga, čak i u klimatološki relativno ujednačenom mediteranskom Izraelu su varijacije na lokalnim područjima bile dovoljne da naprave jasne, iako ne nužno i presudne razlike u modelu. Zbog toga se postavlja pitanje koliko bi rezultati takvih mjerenja i model koji se na osnovu njih napravi bili primjenjivi u kontinentalnoj Europskoj klimi ili poljima pamuka u Uzbekistanu. Naravno, moguće je da bi se istraživanjima u više klimatoloških zona i upotrebom složenijeg modela mogle nadići ove prepreke.

Proučavanje veze između I_{Ga} i g_{sa} termografskim snimanjem se pokazalo kao opravdano, no za sobom vuče više nepoznanica i manje korelacije nego kod metode s korištenjem CWSIa. Od autora čiji su radovi ovdje obrađeni, Grant [3] [6] [8] jedina stalno koristi I_G , dok izraelski autori u pravilu koriste samo CWSI u svojim kasnijim radovima. Kako u literaturi postoji konsenzus oko korištenja CWSIa, tada je istraživanje koje se temelji na njemu kasnije puno lakše usporedivo s ostalima.

3.4. Analiza potencijala primjene

Kako je bilo riječi u prethodnom dijelu, rezultati mjerenja i razvijeni modeli su do sada pokazali određenu ograničenost u pitanju primjenjivosti izvan specifičnih mikroklimatskih uvjeta u kojima su napravljeni. To ograničava brzinu razvoja ove tehnologije jer trenutno zahtjeva da se provode dugotrajna mjerenja na lokaciji da bi se mogao dobiti pouzdan model za tu lokaciju. S druge strane, to nije nedostatak koji bi dugoročno spriječio primjenu ove

tehnologije. Kako bude ulazila u rašireniju primjenu istraživači i poljoprivredni proizvođači će stjecati sve veću bazu mjerenih podataka na osnovu kojih će moći razvijati sve preciznije modele za pojedine lokacije. U teoriji sustav bi, uz adekvatnu metodu strojne analize i prikupljanja mjerenih podataka (što se ionako radi na komercijalnim poljima), mogao sa svakom godinom postajati sve precizniji u određivanju veze između temperaturnih indeksa i vodnog potencijala.

No, da bi to uopće bilo moguće potrebno je prije svega razviti adekvatan model obrade i analize mjerenih podataka. Jer iako su krajnji rezultati možda i različiti za različite vrste, sorte, faze rasta i klimatske uvjete, sama osnovna linearna veza između CWSIa i LWPa koja proizilazi iz teoretskih postavki bi trebala biti takva u svim uvjetima. Točnom potvrdom ove veze, i određivanjem svih relevantnih veličina koje na nju utječu, njena primjena u različitim klimatskim uvjetima postaje samo pitanje vremena.

Konačno, neizostavljiva stavka u primjeni je praktičnost. Kao što se pokazalo u istraživanju od Grant u nekim slučajevima prirodna orijentacija listova je toliko nepovoljna da postaje nemoguće koristiti izmjerene temperature za bilo kakvu analizu. Također, u nekim fazama rasta pamuka ili vinove loze pokrivenost krošnje lišćem nije dovoljna da bi se dobro moglo razaznati lišće od okolnog tla. Ta ograničenja, iako ne nepremostiva sofisticiranim načinima obrade i analize podataka, znače da je primjena ove tehnologije ograničena ili nemoguća na nekim usjevima pri trenutnom stupnju razvoja tehnologije. S druge strane, ondje gdje je sada primjenjiva je njena praktičnost značajno veća od metoda koje zahtijevaju izravno mjerenje na pojedinim biljkama, a zbog toga što je moguće stalno mjerenje je i mogućnost nadzora usjeva neusporedivo veća.

Sve u svemu, termografija ima velik potencijal u primjeni za upravljanje sustavima navodnjavanja, te bi se uspješnom primjenom ove tehnologije mogla povećati kvaliteta proizvodnje i smanjiti njeni troškovi.

4. TERMOGRAFSKO SNIMANJE PRESADNICA PAPRIKE (*Capsicum annuum* L.)

Da bi se mogli dobiti korisni podatci i zaključci potrebno je razviti adekvatnu metodu snimanja i analize podataka. U tu svrhu postavljen je laboratorijski eksperiment u kontroliranim uvjetima kojim bi se detaljnije proučila problematika termografskog snimanja i analize termograma kod biljnih uzoraka. Takvim snimanjem se može dobiti puno bolji referentni uzorak na osnovu kojeg se mogu ocjenjivati kvaliteta i uspješnost terenskih mjerenja u realnim uvjetima uzgoja. Osim toga, omogućava se znatno detaljnije praćenje procesa nego što je moguće postići kod terenskog mjerenja u kojemu se kamera mora stalno pomicati da bi se snimili različiti uzorci.

4.1. Mjerna linija

Ovaj eksperiment je proveden na uzorku presadnica paprike. Paprike su odabrane kao uzorak zbog povoljnije gustoće nadzemnog dijela biljke i veličine listova nego kod presadnica rajčice u istom stupnju rasta. Presadnice su bile starosti 6 tjedana i ujednačene veličine. Nalazile su se u paleti od ekspaniranog polistirena, a paleta je sadržavala četrdeset presadnica. Polovica palete, tj. dvadeset presadnica, je odabrano kao uzorak koji će biti dobro navodnjavan, dok je druga polovica palete bila nenavodnjavana, tj. izložena vodnom stresu. Snimanje je provedeno dok kod one polovice biljaka koja je bila izložena vodnom stresu nije nastupilo venuće.

Paleta s uzorcima je bila postavljena na metalnom plehu koji je prikupljao vodu koja je otjecala iz navodnjavanih uzoraka. Pri tome su korišteni oslonci kojima je paleta izdignuta iznad pleha da bi se izbjeglo da korijenje nenavodnjavanih biljaka eventualno povuče višak vode nakupljene u plehu. Na paleti je markerom označena granica između pojedinih uzoraka (navodnjavanog i nenavodnjavanog), a na termografskim snimcima je ista oznaka napravljena korištenjem reflektivne olovke. Sve navedeno je bilo postavljeno na stolu u zatvorenom kabinetu pored prozora orijentiranog na zapad. Iza pleha je bila postavljena ploča od ekspaniranog polistirena koja je osiguravala da pozadina termograma bude ujednačena, i sprječavala da se eventualno snimi mjeritelj u prolazu iza stola tijekom automatskog snimanja.

Slika 19, slikana zadnjeg dana mjerenja, prikazuje kako je uzorak paprike bio postavljen.



Slika 19. Mjerna linija za mjerenje na paprikama

Za snimanje je korištena termografska kamera tipa SC2000 proizvođača FLIR. Tablica 2 prikazuje radne karakteristike ove kamere.

Tablica 2. Svojstva korištene termografske kamere

Svojstvo	Veličina / raspon
Točnost	$\pm 2\%$ ili $2\text{ }^{\circ}\text{C}$
Mjerna osjetljivost	$0,07\text{ }^{\circ}\text{C}$ pri 30°C
Vidno polje	$24^{\circ} \times 18^{\circ} / 0,3\text{ m}$
Radna temperatura	$-15\text{ }^{\circ}\text{C}$ do $50\text{ }^{\circ}\text{C}$
Područje osjetljivosti	$7,5\text{ }\mu\text{m}$ do $13\text{ }\mu\text{m}$
Detektor	FPA 320x240 px (nehlađeni bolometar)

Kamera je bila postavljena na tronošcu na pomičnim kolicima koja su bila zakočena. Time se osigurao potreban kut snimanja i vidljivost cijelog uzorka. Kamera je bila udaljena 1,2 m od uzorka i na visini od 1,2 m iznad kote dna palete. Kamera je ručno namještena, prilagođen fokus i kut snimanja. Snimanje je bilo automatsko, korištenjem softvera kamere, svakih deset minuta. Snimanje je provedeno 9., 10., 12. i 15. svibnja 2017.



Slika 20. Položaj kamere

Podatci o temperaturi su bilježeni termoparovima tipa T (bakar-konstantan) razreda točnosti $\pm 0,1$ °C. Napon generiran na termoparovima je pretvaran na A/D pretvaraču Agilent 34972A u digitalni signal i bilježen na računalu u pripadajućem programu Agilent Benchlink Data Logger. Podatci su neprekidno bilježeni u intervalu od svakih deset minuta od 11:20 h 09.05. do 16:30 h 15.05.2017. Time je dobiven set od 896 mjernih točaka temperature s obzirom na koje su se mogle analizirati termografske snimke.

Mjerenja temperature su provedena na osam točaka. U svakoj od grupa, navodnjavanoj i nenavodnjavanoj, odabrana je jedna referentna biljka. U toj biljci su umetnuti termoparovi u vrh stabljike neposredno uz list i u podnožje stabljike malo iznad tla. Još je jedan termopar postavljen u tlo pored te biljke da bi se dobila tri mjerna mjesta u svakoj grupi. Sedmi termopar je korišten da mjeri temperaturu u vlažnom uzorku zemlje bez biljke. Osma mjerna točka je korištena za mjerenje temperature okoliša. Položaji termoparova su prikazani na slici 21.

Na kasnijim dijagramima i za potrebe analize se temperatura stabljike neposredno uz list koristila kao ϑ_{list} . Iako ove dvije temperature nisu identične, može se pretpostaviti da će iste zakonitosti koje vrijede za list vrijediti i za stabljiku u njegovoj neposrednoj blizini, te se na taj način dobiti CWSI koji će biti dovoljno reprezentativan za cijelu biljku. Temperatura u podnožju stabljike označena s ϑ_{stab} , a temperatura u tlu pored biljke je označena sa ϑ_{tlo} .




Slika 21. Postavljanje termoparova u uzorke

Uz ova mjerenja provedeno je i mjerenje temperature i relativne vlažnosti zraka ručnim mjeračem prilikom svakog navodnjavanja. Ovi rezultati nisu korišteni u daljnjoj analizi, ali su korišteni tijekom provedbe mjerenja da bi se stekao orijentacijski uvid u stanje u prostoriji i da bi se po potrebi mogli otvarati prozori ili pritvoriti rolete na prozorima. Tijekom mjerenja prozor u prostoriji nije otvaran, niti je itko boravio u prostoriji izvan termina mjerenja.


4.2. Rezultati mjerenja

Temperature mjerene termoparovima su imale veći broj zapisa u vremenu jer je iz praktičnih razloga snimanje termografskom kamerom bilo ograničeno na period radnog vremena laboratorija, dok je mjerenje termoparovima moglo biti provedeno kroz cijeli dan, čak i na dane kada termografska mjerenja nisu rađena. Time su dobiveni kontinuirani podatci o promjeni temperatura tijekom sedam dana. Ovi podatci daju jasan uvid u ponašanje temperature na različitim mjernim mjestima u i pored biljke tijekom različitih doba dana.

Rezultati mjerenja temperatura termoparovima prikazani su na slici 22. za navodnjavani uzorak i slici 23. za nenavodnjavani uzorak.



Slika 22. Temperature za navodnjavani uzorak mjerene termoparovima




Slika 23. Temperature za nenavodnjavani uzorak mjerene termoparovima

Vidljivo je da temperatura mjerena u biljci i tlu prati temperaturu okoliša u prostoriji, ali i da je niža od nje. Na nenavodnjavanom uzorku su temperature mjerene u stabljici kod lista i u bazi stabljike skoro jednake, a uz izuzetak prvih 24 sata mjerenja i temperatura tla za ovaj uzorak je skoro jednaka temperaturama u biljci. Očit je skok koji se dogodio u temperaturi tla nenavodnjavanog uzorka u prijepodnevnim satima 10.05. Upravo u to vrijeme je zalijevan navodnjavani uzorak, te je moguće da je termopar koji je mjerio temperaturu u tlu pomaknut bliže površini ili u izravni kontakt s biljkom, pa da je to uzrokovalo ovakve rezultate.

Najviše temperature su zabilježene u kasnijim popodnevnim satima što je očekivano s obzirom na zapadnu orijentaciju prozora u prostoriji. Vidljivo je da u periodu jake izravne insolacije i temperatura biljke i temperatura tla i temperatura zraka u prostoriji naglo skaču, te se zatim i naglo spuštaju kada sunce zađe. Može se primijetiti da su ove vršne temperature bile znatno niže 11.05. i 14.05., što je vjerojatno posljedica toga što je insolacija bila manja u kasno popodne ta dva dana.

Kao neočekivan rezultat mjerenja pojavila se činjenica da su temperature u stabljici kod lista navodnjavanog uzorka u pravilu bile više od temperatura u stabljici kod lista nenavodnjavanog uzorka. Ovo je u suprotnosti s rezultatima dobivenima termografskim snimanjem, i očekivanim vrijednostima prema poznatom ponašanju biljaka izloženih vodnom stresu. Razlog tom neočekivanom ponašanju je vjerojatno u činjenici da je mjerenje temperature nenavodnjavanog uzorka obavljeno na jednoj od biljaka na sredini palete gdje su biljke iz nenavodnjavanog uzorka preko palete povukle vodu namijenjenu navodnjavanom uzorku.

Slika 24. prikazuje međusobni odnos temperatura lista ova dva uzoraka.




Slika 24. Temperature lista dobivene mjerenjem termoparovima

Rezultati termografskog mjerenja su bili termogrami tijekom četiri dana mjerenja. Termogrami su snimani u rainbow paleti boja, no za potrebe obrade rezultata su prebačeni u greyscale paletu boja. Ova paleta sadrži 256 nijansi sive, kojima se prilikom učitavanja u MatLab dodjeljuje broj od 0 do 1, čime se jednadžba (6) presložila u jednadžbu (21):

$$\vartheta_{(x,y)} = \vartheta_{min} + \frac{GL_{(x,y)}}{255} * (\vartheta_{max} - \vartheta_{min}) \quad (21)$$


Termogrami prikazani na slici 25. su, redom s lijeva na desno i odozgo prema dolje, od 09.05., 10.05., 12.05. i 15.05. Vidljivo je da je razlika između termograma snimljenih 09.05 i 10.05 mala, dok se na termogramu od 12.05. već počinje primjećivati razlika u nenavodnjavanom dijelu. Tu su problem predstavljale dvije biljke koje se mogu vidjeti u prvom redu, a na kojima je tog dana konstantno mjerena značajno viša temperatura. Tijekom mjerenja nije primijećen razlog zbog kojega su se one ponašale toliko različito od ostalih biljaka. U kasnijoj obradi se njih zanemarilo jer se nije moglo utvrditi koji je razlog njihovoj toliko povišenoj temperaturi. Na termogramu snimljenom zadnjeg dana snimanja može se uočiti da su biljke po obodu nenavodnjavanog dijela već počele venuti i da je tu uzorak vidno drugačiji. Dio biljaka u sredini palete na nenavodnjavanoj strani je očito uspio kroz paletu povući nešto vode s navodnjavane strane, te je pokazivao ponašanje identično biljkama na navodnjavanoj strani.



Slika 25. Snimljeni termogrami tijekom mjerenja na paprici


Kako su snimljeni termogrami prikazivali oba uzorka tada je da bi ih se moglo interpretirati bilo potrebno odrediti područja termograma koja predstavljaju pojedini uzorak. Ovo je napravljeno tako da se napravila dodatna bitmapa identičnih dimenzija kao i termogram, te se na njoj bijelim pravokutnikom označila željena površina. Ostatak bitmape je bio crn. Bijelim područjima je dodijeljena vrijednost 1, a crnima 0, te je ranije dobivena matrica temperatura pomnožena s tako dobivenim vrijednostima. Rezultat su bile dvije matrice koje su sadržavale samo vrijednosti temperatura sa željenih područja termograma. Odabir područja koja će se promatrati je napravljen za svaki od promatranih dana pojedinačno jer je prilikom postavljanja kamere svakog od tih dana došlo do malih pomaka, te se filter napravljen za jedan dan nije mogao koristiti na termogramima snimljenima drugoga. dana Uz to se i sam uzorak mijenjao, te je zadnja dva dana snimanja površina nenavodnjavanog uzorka koju se moglo analizirati bila značajno smanjena.

Slika 26. prikazuje primjenu filtra na termogramima prikazanima na slici 24. Plavom bojom označen je filter za navodnjavani, a crvenom bojom filter za nenavodnjavani uzorak.



Slika 26. Snimljeni termogrami tijekom mjerenja na paprici

Iz gornje slike se vidi da je bio problem odrediti odgovarajuće veliku površinu za obradu na nenavodnjavano uzorku tijekom zadnja dva dana jer je dio biljaka počeo venuti, a dio je pokazivao abnormalno visoke temperature. Dobivene temperature su prikazane na slici 27.




Slika 27. Temperature lista dobivene termografskim snimanjem

Temperature listova uzoraka su skoro identične tijekom prva tri dana snimanja, dok se veća razlika uočava tek posljednjeg dana snimanja kada temperatura listova nenavodnjavanog uzorka postaje nešto viša od temperature listova navodnjavanog uzorka. Ova razlika ipak nije toliko naglašena koliko bi bilo očekivano s obzirom na činjenicu da je nenavodnjavani uzorak do tada bio preko pet dana bez navodnjavanja i da su neke biljke počele venuti. S druge strane tijekom same obrada termograma je bilo nužno odbaciti pojedine dijelove uzorka koji su pokazivali najveće znakove vodnog stresa jer njihovi listovi nisu više bili adekvatni za termografsko snimanje. Ovo je vjerojatno nepovoljno djelovalo na relevantnost rezultata jer takva metoda preferencijalno prikazuje samo one biljke u nenavodnjavanom uzorku koje su bile u boljem stanju.

4.3. Analiza rezultata mjerenja

Na osnovu temperatura dobivenih mjerenjem i prikazanih u prethodnom potpoglavlju napravljen je izračun temperaturnog indeksa CWSI prema jednadžbi (4). Prvo je napravljen okviran izračun CWSIa prema temperaturama mjerenima termoparovima, zasebno za


navodnjavani i nenavodnjavani uzorak. Tu je kao ϑ_{leaf} korištena temperatura izmjerena termoparom kod lista biljke. Suha referentna temperatura određena je jednadžbom (5). Vlažna referentna temperatura je određena kao najniža zabilježena temperatura tla kod bilo kojeg od mjerenih uzorka. Prikaz dobivenih vrijednosti CWSIa je dan na slici 28.



Slika 28. Vrijednosti CWSI prema mjerenju termoparovima

Vidljivo je da je CWSI dobiven u ovoj analizi suprotan onome koji bi se očekivao iz poznatog ponašanja biljke pod vodnim stresom, što je posljedica činjenice da su temperature lista nenavodnjavanog uzorka bile više od onih navodnjavanog uzorka. Osim toga se i izabrana vlažna referentna temperatura pokazala nepouzdanom, te dolazi do negativnih vrijednosti CWSI tijekom dnevnih maksimuma temperature okoliša. Ovakvi rezultati su neočekivani i ukazuju na to da je bilo potrebno odabrati reprezentativniju biljku za mjerenje temperature nenavodnjavanog uzorka, te eventualno mjeriti temperaturu vlažnog termometra kao alternativu za vlažnu referentnu temperaturu.

Identična analiza kao i za termoparovima izmjerenu temperaturu napravljena je i za temperature dobivene termografskim snimanjem. Jedinu razliku predstavljala je vlažna referentna temperatura, koja je u ovom slučaju određena kao ona temperatura $\vartheta_{10\%}$ na termogramu od koje je niže točno 10% zabilježenih temperatura na termogramu. Ovaj način određivanja vlažne referentne temperature u svom radu je ranije uspješno upotrijebio Alchanatis. Dobivene vrijednosti CWSIa su prikazane na dijagramu na slici 29.




Slika 29. Vrijednosti CWSI prema termografskom mjerenju

Na gornjem dijagramu je vidljivo da je dobivena očekivana raspodjela CWSI, pri čemu su oba uzorka imali približno jednak CWSI tijekom prva dva dana, a zatim je CWSI nenavodnjavanog uzorka rastao, dok je CWSI navodnjavanog uzorka ostao približno konstantan. CWSI je uvijek bio najveći neposredno prije zalijevanja, odnosno ujutro. Zadnjeg dana snimanja je primjetna velika razlika u CWSIu između nenavodnjavanog uzorka kod kojeg je već počelo venuće i navodnjavanog uzorka koji je imao rezultate slične kao i prvog dana.

Pogledom na skalu dijagrama na slici 29. vidljivo je da su vrijednosti CWSIa, iako u očekivanom relativnom odnosu, pokazale neočekivane apsolutne vrijednosti. Tako biljke nenavodnjavanog uzorka kod kojeg je počelo venuće 15.05. imaju CWSI od samo 0,09 do 0,11. Ovo ukazuje da je loše odabrana suha referentna temperatura, te da je najviša temperatura lista biljke paprike pod maksimalnim vodnim stresom bila značajno niža od pretpostavljene. Ovo znači da je u jednadžbi (5) za ovaj slučaj potrebno smanjiti dodatak s 5 °C na neku nižu vrijednost.

Slika 30 prikazuje vrijednosti CWSIa, samo za nenavodnjavani uzorak, dobivene za veći broj odabranih suhih referentnih temperatura.




Slika 30. Vrijednosti CWSIa za različite suhe referentne temperature

Gornji dijagram jasno prikazuje da su pri nižim suhim referentnim temperaturama na uobičajenoj skali za prikazivanje CWSIa puno izraženije i vidljivije zabilježene promjene biljke nego što je to slučaj kada se koristi suha referentna temperatura koja je značajno viša od stvarne. Ove promjene su jednako vidljive i s višim suhim referentnim temperaturama, kao primjerice na slici 29., no tada se zahtjeva korištenje prilagođene skale za CWSI. S obzirom na to da je jednadžba (5) samo aproksimacija i pojednostavljenje modela, tada je potrebno promijeniti izraz dan jednadžbom (5) da bi apsolutne vrijednosti CWSIa ostale u predviđenom rasponu. U ovom slučaju se jednadžba (5) pretvara u jednadžbu (22):

$$\vartheta_{dry} = \vartheta_{air} - 0,5 \text{ }^{\circ}\text{C} \quad (22)$$

Slika 31. prikazuje vrijednosti CWSIa za oba uzorka dobivene uz ovaj ϑ_{dry} .

Može se zaključiti da je analizom rezultata termografskog snimanja dobiven očekivan raspored vrijednosti CWSI za odgovarajuće uzorke kroz pojedine dane snimanja. Iz ovoga slijedi da je primjena termografije i analiza dobivenih termograma metodom koja je ovdje opisana pouzdan način određivanja CWSI za presadnice paprike. Razumna je pretpostavka da bi se sličan uspjeh mogao ostvariti i snimanjem drugih sličnih vrsta presadnica u usporedivim uvjetima.



Slika 31. Vrijednosti CWSIa za novu suhu referentnu temperaturu

S druge strane, temperature listova mjerene termoparovima su pokazale odstupanje od očekivanih vrijednosti. Dobivene vrijednosti bi sugerirale da je temperatura u stabljici kod lista dobro navodnjavane biljke viša od temperature u stabljici kod lista biljke pod visokim vodnim stresom, što nije moguće. Pretpostavka je da je ovakav rezultat posljedica lošeg odabira referentne biljke na kojoj su provođena mjerenja za nenavodnjavani uzorak, jer je odabrana biljka bila u sredini uzorka i preblizu navodnjavane polovice palete, te je vjerojatno kroz paletu mogla povlačiti vodu. Time je postala potpuno nereprezentativna za nenavodnjavani uzorak. U daljnjem istraživanju je potrebno obratiti strogu pažnju na odabir referentnih biljaka na kojima će se provesti mjerenje termoparovima, te osigurati da su one reprezentativne za promatrani uzorak.

5. TERMOGRAFSKO SNIMANJE PRESADNICA RAJČICE (*Lycopersicon esculentum* Mill.)

Nakon što je verificirana mogućnost primjene termografije pri snimanju presadnica na primjeru biljaka paprike, idući korak je bio napraviti istraživanje kojime će se dobiti upotrebljiva veza između fizioloških odgovora biljke na vodni stres i temperatura dobivenih termografskim snimanjem. Istraživanje se primarno fokusiralo na vezu između CWSIa i vodnog potencijala lista. Uz to je napravljena analiza veze između temperature i drugih mjerenih bioloških veličina.

Uzorak za ovo istraživanje su bile presadnice rajčice za preradu (*Lycopersicon esculentum* Mill., sorta Red Valley H1). U zaštićenom prostoru specijaliziranog proizvođača presadnica (Rasadnik Longo, Rovinj) 24. ožujka 2017. provedena je ručna sjetva sjemena dezinficiranog u 10 % otopini vodikovog peroksida.. Budući da su presadnice uzgajane za potrebe pokusnih istraživanja Instituta za poljoprivredu i turizam u Poreču polovica od ukupnog broja presadnica bila je nacijepljena mikoriznim gljivama.

Mikoriza je uzajamna biološka zajednica fotoautotrofni biljaka i gljiva za koju je karakteristično da hife micelija prodiru u stanice korijena biljke domaćina. Mikorizom gljive i biljke postižu obostranu korist, zahvaljujući tome da micelij predstavlja u tom slučaju produžetak korijena, putem kojeg biljke lakše dolaze do vode i hranjiva, dok gljive od biljke pretežito dobivaju ugljikohidrate i određene organske spojeve. Provedena istraživanja pokazala su da mikorizirane biljke imaju veći relativni sadržaj vode i bolju iskoristivost vode u uvjetima suše (vodnog stresa) u usporedbi s nemikoriziranim biljkama. Istraživanja su pokazala da posljedice vodnog stresa mogu biti ublažene kod biljaka kod kojih je aktivirana mikoriza zahvaljujući povećanoj fotosintetskoj aktivnosti. [13]

Mikorize su neposredno prije sjetve miješane sa supstratom Klassman KKS BIO-Potgrond, aplicirane su "Aegis microgranule" mikorize [14] u količini 1 g mikoriza na 50 ml supstrata (1 g preparata ima 50 spora, tako da je primijenjena 1 spora na 1 ml supstrata). Presadnice su uzgojene uz uobičajene mjere njege i navodnjavanje presadnica, a uzgajane su u rasadniku dok nisu razvile 3-4 lista (visina do 10 cm).

Slika 32. prikazuje presadnice u zaštićenom prostoru rasadnika Longo u Rovinju nakon nešto manje od mjesec dana rasta. Slika je napravljena 13. travnja 2017.



Slika 32. Presadnice u plasteniku rasadnika Longo, Rovinj

Za potrebe termografskog snimanja odabrane su dvije palete presadnica od kojih je jedna paleta s četrdeset presadnica bila zasađena s rajčicama nacijepljenim mikoriznim gljivama, a druga paleta s također četrdeset presadnica je bila zasađena s rajčicama koje nisu bile nacijepljene.

Presadnice stare šest tjedana dostavljene su 3. svibnja 2017. u Zagreb na Agronomski fakultet. U zaštićenom prostoru Agronomskog fakulteta presađene su 4. svibnja 2017. s grudom supstrata u plastične sadne lončice volumena 1,1 L u kojima je bila postavljena plastična vrećica koja je sprječavala gubitak vode kroz dno posude. Za sadnju je korišten gotovi komercijalni supstrat. Svaki sadni lončić označen je naljepnicom prema planiranim tretmanima pokusa:

- mikoriza nenavodnjavano
- mikoriza navodnjavano
- bez mikorize nenavodnjavano
- bez mikorize navodnjavano

Svaka biljka je i numerirana. Navodnjavane grupe su označene brojevima 1-20, a nenavodnjavane brojevima 21-40.

Slika 33. prikazuje presađene rajčice u sadnim lončićima volumena 1,1 L.



Slika 33. Rajčice presađene u sadne lončice


Kada je obavljeno presađivanje rajčica, određena je ukupna masa svakog zasađenog lončića. Obavljeno je navodnjavanje (ručno zalijevanje vodovodnom vodom) s 280-300 g vode po lončiću, ovisno o određenoj masi lončića sa supstratom i biljem. Presadnice su uzgajane u zaštićenom prostoru sljedećih 12 dana, odnosno dok se nije postigao zadovoljavajući razvoj stabljike i pokrivenost lišćem. Tijekom tih 12 dana navodnjavane su sve presadnice prema prethodno navedenom postupku svaki drugi dan. Prihrana vodotopivim mineralnim gnojivom (Polyfeed, N:P:K 9:12:39) obavljena je dva puta, drugog i osmog dana nakon sadnje u lončice. Nakon što su biljke dostigle željenu veličinu (16. svibnja 2017.) prenesene su u susjedni plastenik gdje je postavljena mjerna linija za termografsko snimanje.

5.1. Mjerna linija za termografiju

Uzorci biljaka su bili podijeljeni u četiri grupe. Sve grupe su imale dvadeset biljaka osim mikorizirane navodnjavane grupe koja je imala osamnaest. Naime, dvije biljke u toj grupi su odbačene prije snimanja zato što jedna biljka nije nikla, a druga biljka nije narasla na potrebnu veličinu nego je ostala znatno manja od drugih biljaka uzorka. Biljke u pojedinom uzorku su složene na EPS palete na točno određen način prema brojevnim oznakama pojedinih posuda. Slika 34. shematski prikazuje mjernu liniju, a slika 35. fotografski prikazuje isto.



Slika 34. Prikaz jednog uzorka za mjerenje



Slika 35. Mjerna linija za rajčice

Prije nego su postavljene na svoja mjesta sve biljke su izvagane na analitičkoj vagi. Prvi dan su sve biljke navodnjavane, i to obje navodnjavane grupe sa 150 mL vode, a obje nenavodnjavane grupe sa 100 mL vode. Drugog i trećeg dana mjerenja je vaganje ponovljeno

odmah po dolasku u plastenik. Tada je biljkama iz navodnjavanih skupina dodavano toliko destilirane vode koliko je bilo potrebno da ponovno postignu masu koju su imale prvog dana. Nenavodnjavanim biljkama je samo zabilježena masa, te ih se nije uopće navodnjavalo.

Po uzoru na mjerenje na paprikama i ovdje su prikupljani podatci o temperaturi pomoću Agilent Dataloggera. Podatci o ovom uređaju su dani u poglavlju 4.1. Korišteni su termoparovi T-tipa s odgovarajućim kompenzacijskim kablovima. U svakoj grupi je izabrana jedna biljka u koju su umetnuta dva termopara. Jedan u stabljiku neposredno prije prve grane, a drugi u peteljku jednog većeg lista. Treći termopar je umetnut u tlo posude te biljke.

Biljke izabrane za mjerenje temperatura termoparovima su bile na identičnim pozicijama u svim grupama. U navodnjavanim grupama su to bile biljke u posudama broj 12, a u nenavodnjavanim grupama su to bile biljke u posudama broj 32. Slika 36. prikazuje brojčane oznake i položaj pojedinih biljaka u navodnjavanom uzorku bez mikorize, a posebno je naznačen položaj odabrane biljaka za provođenje mjerenja termoparovima. Identičan raspored i odabir biljke je korišten i kod drugog navodnjavanog uzorka. U nenavodnjavanim uzorcima je korišten ekvivalentan raspored biljaka, uz razliku da su kod njih brojčane oznake išle od 21 do 40.



Slika 36. Odaabrane biljke za mjerenje termoparovima

Slika 37. prikazuje položaj termoparova na biljci. Lijeva polovica slike pokazuje položaj termopara u stabljici kod lista, a desna termoparove u dnu stabljike i u tlu pored biljke.



Slika 37. Položaj termoparova u bilji

Na dataloggeru se dodatnim termoparom mjerila temperatura zraka. Termopar je bio ovješten s konstrukcije staklenika te se nalazio pola metra iznad razine krošnje grupe nemikoriziranih i navodnjavanih biljaka. Termopar je bio zaštićen od izravnog sunčevog zračenja pomoću aluminijske folije. Ovaj termopar je naznačen i na slici 35. Datalogger je bio spojen na računalo na kojemu se pomoću softvera Agilent Benchlink Data Logger bilježilo izmjerene podatke u intervalu od pet minuta. Po završetku snimanja za pojedini dan podatci su spremljeni u zasebni dokument.

Odsjaj okoliša je ograničen korištenjem EPS panela koji su prilikom snimanja postavljeni iza uzoraka na paletama. Samo termografsko snimanje je provedeno istom kamerom kao i kod paprika, te se podatci o kameri mogu pronaći u tablici 2 u poglavlju 4. Kamera je bila postavljena na tronožac na visini od 1,8 metara iznad tla i nalazila se na udaljenosti od 1,1 metara od uzoraka. Zbog toga što je pod u plasteniku neravan bilo je potrebno kameru uvijek nanovo pozicionirati prije svakog snimanja. Da bi se osigurala što jednoličnija pozicija kamere na podu plastenika su iscertane sve pozicije nožica tronošca. Samo fino podešenje položaja kamere se moralo raditi ručno prilikom svakog snimanja, te zbog toga nije bilo moguće postići istu onakvu jednolikost kao kod paprike niti koristiti automatsko snimanje s vremenskim intervalom. Ipak, takvi uvjeti su standardni u zaštićenim prostorima i na terenu, te su stoga mjerenja provedena u ovim uvjetima relevantnija za razvoj algoritma analize koji bi bio primjenjiv za snimanja provedena u sličnim stvarnim uvjetima uzgoja.

Snimanja su provedena svakih pola sata. Prvo jutarnje snimanje je provedeno u osam sati ujutro paralelno s uzimanjem uzoraka za mjerenje vodnog potencijala lista. Tijekom trećeg dana je u snimanje uključeno i korištenje referentnih listova. Ovo je napravljeno da bi se mogli usporediti s drugim metodama određivanja referentnih temperatura za izračun CWSI, te time validirati odabrana metoda.

5.2. Ostale mjerne linije

U sklopu ovog istraživanja provedena su i mjerenja fizioloških odgovora i svojstava biljke koja su bila potrebna za daljnju analizu. Provedena mjerenja su mjerenje vodnog potencijala lista, mjerenje klorofila lista, mjerenje fotosinteze, mjerenje dušika, mjerenje stabljiki i listova, te mjerenje korijenja. Od navedenih su za termografsko istraživanje relevantna bila mjerenje vodnog potencijala i fotosinteze. Ostala su navedena informativno i nisu korištena u analizi povezanoj s infracrvenom termografijom.

5.2.1. Mjerenje vodnog potencijala lista

Mjerenje vodnog potencijala lista je provedeno u osam sati ujutro 17. i 18. svibnja 2017. Mjerenja su provedena u tlačnoj prenosivoj komori za mjerenje vodnog potencijala lista (Plant water status console, Soilmoisture Equipment Corporation, USA). Ovaj uređaj je prenosivi sustav kojime se mjerenja vrše u stvarnom vremenu te se odluke o navodnjavanju mogu donositi kako se podaci prikupljaju. Mjerenje vodnog potencijala lista daje nam informaciju o vodnom statusu biljke. Količina tlaka potrebna da bi se istisnula voda na odrežanom dijelu peteljke lista odgovara vodnom potencijalu lista, odnosno količini tenzije kojom list drži vodu. Što je veći tlak koji je potreban da bi se istisnula voda iz lista, biljka se nalazi u većem vodnom stresu. Vodni potencijal lista mjeri se u negativnim barima. Biljke će pri većem vodenom deficitu imati veći vodni potencijal lista ili peteljke nego biljke koje nisu pod stresom, odnosno što je negativniji broj, veća je tenzija u unutrašnjosti lista i veći je vodni stres biljke. Mjerenje se provodi tako da se s biljke ostrim nožem odreže potpuno razvijen list. Taj se list zatim stavlja u tlačnu komoru uređaja. U tlačnu komoru se pušta zrak pod tlakom tako dugo dok se na peteljci lista ne uoče mjehurići vode. Tlak u komori u tom trenutku odgovara vodnom potencijalu lista. Prikaz mjerne linije je dan na slici 38.




Slika 38. Mjerna linija za vodni potencijal lista

Svakog dana su iz svake grupe odabrana tri potpuno razvijena lista, koja su odsijecana oštrim nožem, te je na njima mjeren vodni potencijal lista.

5.2.2. Mjerenje fotosinteze

Mjerenje fotosinteze provedeno je u prijepodnevnim satima (u 11 sati) 18. svibnja 2017. Intenzitet fotosinteze (A , $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$) rajčice mjeren pomoću terenskog prenosivog instrumenta LCpro+ portable photosynthesis system, ADC BioScientific Ltd., Great Britain. Mjeren je intenzitet fotosinteze najmlađem fiziološki zrelom listu, na tri biljke po jednoj repeticiji varijante pokusa. Uz podatke o intenzitetu fotosinteze, pomoću LCpro+ photosynthesis system dobiveni su i podaci o koncentraciji intercelularnog CO_2 lista (C_i , $\mu\text{mol mol}^{-1}$), provodljivosti puči (g_s , $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$) te transpiraciji (E , $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$). Istovremeno s mjerenjem intenziteta fotosinteze obavljeno je i mjerenje sadržaja klorofila. Mjerenje je obavljeno terenskim klorofil-metrom (CCM-200 plus Chlorophyll Content Meter, ADC BioScientific Ltd., Great Britain).

Prikaz mjerne linije za mjerenje intenziteta fotosinteze je dan na slici 39.



Slika 39. Mjerna linija za fotosintezu

Iz svake grupe su odabrana tri potpuno razvijena lista, te je na njima provedeno mjerenje.

5.3. Rezultati mjerenja


Mjerenja su provedena tijekom tri različita dana: 16., 17. i 18. svibnja 2017. godine. Pri tome su za daljnju analizu odbačena mjerenja od 16.05. zbog toga što su počela znatno kasnije u danu, te mjerenja vodnog potencijala nisu provedena s dovoljnim uzorkom, nego samo s jednim probnim listom po uzorku. Dana 17.05. i 18.05. su provedena odgovarajuća termografska mjerenja i mjerenje vodnog potencijala, te se ona uzimaju u daljnju analizu. Sva preostala mjerenja navedena u 5.2. su provedena tijekom 18.05.

5.3.1. Rezultati mjerenja termoparovima


Temperature mjerene termoparovima su imale veći broj zapisa u vremenu jer su uključeni i rezultati mjerenja provedeni 16.05.2017.. Rezultati mjerenja temperatura termoparovima prikazani su na slikama 40., 41., 42. i 43. Podatci na ovim slikama nisu

kontinuirani, te okomite linije označavaju prekid mjerenja u popodnevним satima jednog dana i početak mjerenja u jutarnjim satima sljedećeg dana.

Kao i kod uzorka paprika i ovdje je zbog nedovoljne debljine lista termoparovima umjesto temperature lista mjerena temperatura u stabljici kod lista, te upravo ona predstavlja ϑ_{list} na dijagramima. ϑ_{stab} je temperatura mjerena u podnožju stabljike biljke neposredno iznad tla. ϑ_{tla} je temperatura mjerena u tlu posude pored biljke. Slika 40. prikazuje rezultate za navodnjavani mikorizirani uzorak, a slika 41. prikazuje navodnjavani uzorak bez mikorize.




Slika 40. Temperature mjerene termoparovima za navodnjavani mikorizirani uzorak




Slika 41. Temperature mjerene termoparovima za navodnjavani nemikorizirani uzorak

Slika 42. prikazuje nenavodnjavani nemikorizirani uzorak, a slika 43. prikazuje nenavodnjavani uzorak bez mikorize.




Slika 42. Temperature mjerene termoparovima za nenavodnjavani nemikorizirani uzorak



Slika 43. Temperature mjerene termoparovima za nenavodnjavani mikorizirani uzorak

Vidljivo je da temperatura mjerena u biljci i tlu prati temperaturu okoliša u zaštićenom prostoru, ali i da je niža od nje za navodnjavane uzorke. Na nenavodnjavanom uzorku temperature lista i stabljike su više od temperature okoliša tijekom kasnijih dana mjerenja kada su biljke već bile pod značajnim vodnim stresom. Zadnjeg dana kada je venuće već počelo i smanjena je zaklonjenost tla u nenavodnjavanim uzorcima, došlo je i do porasta temperature tla u tim uzorcima iznad razine temperature zraka u okolišu.

Najviše temperature su zabilježene svaki dan pri kraju mjerenja što je očekivano s obzirom da se do popodneva prostor značajno zagrijao. Usporedba temperatura mjerenih u stabljici kod lista na svim uzorcima dana je na slici 44.




Slika 44. Temperature u stabljici kod lista svih uzoraka mjerene termoparovima

Dobiveni su očekivani rezultati u kojima je temperatura u stabljici kod lista navodnjavanih uzoraka znatno niža od temperature u stabljici kod listova nenavodnjavanih uzoraka tijekom posljednjih dana mjerenja. Temperature u stabljici kod listova oba navodnjavana uzorka su međusobno slične, a isti je slučaj i s temperaturama u stabljikama kod listova oba nenavodnjavana uzorka, tako da se na osnovu temperatura ne može primijetiti značajan utjecaj mikorizacije. Mikorizirani uzorak je u pravilu imao malo niže temperature u stabljikama kod lista u navodnjavanom stanju, a blago više temperature u nenavodnjavanom stanju.

5.3.2. Rezultati termografskog mjerenja

Rezultati termografskog mjerenja su bili termogrami snimljeni tijekom dva dana mjerenja. Termogrami su snimani u rainbow paleti boja, no za potrebe obrade rezultata su prebačeni u greyscale paletu boja i obrađivani uz korištenje jednadžbe (21) na isti način kao i snimke paprika.


Termogrami prikazani na slici 45. su, redom s lijeva na desno i odozgo prema dolje, od 17.05. ujutro, 17.05. popodne, 18.05. ujutro i 18.05. popodne. Prikazani termogrami su nemikoriziranog uzorka izloženog vodnom stresu. Vidljivo je da je razlika između termograma snimljenih 17.05. manja, dok se na termogramima od 18.05. već primjećuje smanjena površina listova koja je posljedica venuća biljke. S obzirom na to da se kamera morala svaki put namještati ispočetka vidljivo je da ovi termogrami nisu međusobno apsolutno jednaki po sadržaju kadra, te da svaki termogram zahtjeva zasebnu obradu.



Slika 45. Snimljeni termogrami tijekom mjerenja na rajčici


Izrada i primjena filtera napravljena je metodom razvijenom tijekom obrade termograma uzoraka paprike. Kao što je i ranije rečeno, za razliku od obrade kod paprika ovdje je svaki pojedini termogram morao dobiti vlastiti filter jer se nijedan termogram nije u potpunosti poklapao s bilo kojim drugim po površini koju je snimio.

Slika 46. prikazuje primjenu filtra na termogramima prikazanim na slici 45.



Slika 46. Primjena filtera na termogramima rajčice

Dobivene temperature ovakvom analizom termograma prikazane su na slici 47.



Slika 47. Temperature lista rajčice dobivene termografskim snimanjem

Vidljivo je da temperature dobivene termografskim snimanjem prate sličan trend kao i one dobivene mjerenjem termoparovima. I ovdje kao i u prethodnom slučaju okomita crta predstavlja granicu između dana mjerenja, a podaci nisu kontinuirani između dva dana mjerenja. Primjetno je da se tijekom zadnja dva mjerenja temperatura na mikoriziranom nenavodnjavanom uzorku neočekivano spustila što je vjerojatno posljedica činjenice da je na tom uzorku venuće bilo najizraženije i njegovi listovi više nisu stvarali zadovoljavajuće gustu površinu listova na kojoj bi se mogli dobiti pouzdani rezultati mjerenja. Unatoč tome može se zaključiti da su mjerenja dala očekivane rezultate u najvećem broju slučajeva, te da se jedino moraju isključiti mjerenja u kojima gustoća listova nije zadovoljavajuća.

5.3.3. Rezultati mjerenja vodnog potencijala

Rezultati dobiveni mjerenjima 16. svibnja 2017. koja su provedena na samo jednom listu iz svake grupe nisu uzimana u obzir u daljnjoj analizi jer nisu predstavljala statistički značajan uzorak.

Mjerenjima tijekom preostala dva dana su dobiveni rezultati prikazani u tablici 3.

Tablica 3. Pregled izmjerenih vrijednosti LWPa

Datum	17.05.2017.			18.05.2017.		
Mjerenje	1	2	3	1	2	3
Grupa	MPa	MPa	MPa	MPa	MPa	MPa
Mikoriza navodnjavano	-0,600	-0,800	-0,800	-1,000	-0,500	-0,800
Bez mikorize navodnjavano	-0,300	-0,350	-0,300	-0,200	-1,000	-0,200
Bez mikorize nenavodnjavano	-0,300	-0,700	-0,950	-1,400	-1,100	-1,250
Mikoriza nenavodnjavano	-0,600	-0,500	-0,400	-1,650	-1,500	-1,500

U daljnjoj analizi je kao LWP za pojedinu grupu i dan korišten prosjek sva tri mjerenja tog dana. Time su dobivene dvije vrijednosti LWPa za svaku grupu, te se na osnovu njih i termografskih snimki napravljenih u isto vrijeme i istog dana mogla napraviti daljnja analiza veze između CWSIa i LWPa za ove uzorke.

5.3.4. Rezultati mjerenja fotosinteze

Mjerenjima su dobiveni rezultati prikazani u tablici 4.

Tablica 4. Pregled izmjerenih vrijednosti A i g_s


Veličina	A			g_s		
Mjerenje	1	2	3	1	2	3
Grupa	-	-	-	-	-	-
Mikoriza navodnjavano	24,04	14,67	22,27	0,22	0,09	0,19
Bez mikorize navodnjavano	13,12	23,33	18,51	0,12	0,16	0,13
Bez mikorize nenavodnjavano	1,16	5,80	1,37	-	-	-
Mikoriza nenavodnjavano	1,37	1,07	1,15	-	-	-

Zbog toga što je već počelo venuće na nenavodnjanim uzorcima na njima nisu uspjela mjerenja otvorenosti puči i fotosinteze. To znači da postoje samo rezultati za navodnjavane uzorke, te da neće biti moguće razviti model veze između otvorenosti puči i temperaturnih indeksa.

5.4. Analiza rezultata

Temeljem rezultata mjerenja temperatura napravljen je izračun temperaturnog indeksa CWSI prema jednadžbi (4). Metoda analize je bila identična onoj razvijenoj na uzorku paprike u prethodnom poglavlju. Prvo je napravljen okviran izračun CWSIa prema temperaturama mjerenima termoparovima, zasebno za svaki od četiri uzorka. Ovdje je također napravljena pretpostavka da je mjerena temperatura u stabljici kod lista jednaka temperaturi tog lista. U stvarnosti je ta temperatura u pravilu viša, te su stoga ovako dobiveni rezultati CWSIa nešto veći od onih koji bi se dobili mjerenjem u samome listu. Suha referentna temperatura određena je neizmijenjenom jednadžbom (5). Vlažna referentna temperatura je određena kao najniža zabilježena temperatura tla kod bilo kojeg od mjerenih uzorka.

Prikaz dobivenih vrijednosti CWSIa je dan na slici 48.



Slika 48. Vrijednosti CWSI za rajčice prema mjerenju termoparovima


Za razliku od mjerenja na paprikama, vidljivo je da je CWSI dobiven u ovoj analizi upravo onakav kakav je i očekivan iz poznatog ponašanja biljke pod vodnim stresom. CWSI nenavodnjavanih uzoraka je značajno viši tijekom zadnja dva dana snimanja od CWSIa navodnjavanih uzoraka, te apsolutna vrijednost CWSIa uredno ulazi u raspon od 0 do 1.

Očito je da je u ovom slučaju odabir obje referentne temperature bio opravdan, te stoga nema potrebe za njihovim izmjenama. Može se zaključiti da je i odabir referentnih biljaka u svakom od uzoraka bio dobar, te da su odabrane biljke dobro pokazivale ponašanje cijelog uzorka.

Identična analiza kao i za temperature mjerene termoparovima napravljena je i za temperature dobivene termografskim snimanjem. I ovdje je, kao i kod paprika, kao vlažna referentna temperatura (umjesto temperature tla) uzeta temperatura $\vartheta_{10\%}$. Takav odabir vlažne referentne temperature se pokazao pouzdan na mjerenju kod paprika, a korišten je i u ranijim radovima drugih autora, pa se pretpostavlja da je i za ovo mjerenje dovoljno pouzdan izbor kao ishodišna vrijednost za daljnju analizu.

Za razliku od mjerenja na uzorku paprike, ovdje je bio dostupan manji broj termograma, što je posljedica toga da se kamera nije mogla ostaviti na automatskom snimanju nego se ručno morala pomicati i namještati za svako snimanje na svakom uzorku.

Dobivene vrijednosti CWSIa su prikazane na dijagramu na slici 49.



Slika 49. Vrijednosti CWSI prema termografskom mjerenju rajčice

Na gornjem dijagramu je vidljivo da je razlika u CWSIu između navodnjavanih i nenavodnjavanih uzoraka dobivena analizom termograma nešto manje izražena nego ona dobivena analizom termoparovima mjerenih temperatura listova. Ipak, i ove vrijednosti prate očekivan trend za promatrane uzorke. Uz izuzetak zadnja dva mjerenja na mikoriziranom uzorku izloženom vodnom stresu, a koja su identificirana kao nereprezentativna zbog prevelikog gubitka površine listova, trend koji pokazuju svi uzorci je identičan onom dobivenom u mjerenjima termoparovima. Vjerojatno je da bi stvarni CWSI za ta dva problematična mjerenja trebao biti sličan onome koji pokazuje nemikorizirani nenavodnjavani uzorak.

Odabir referentnih temperatura se pokazao kao opravdan, što je vidljivo iz dobivenih apsolutnih vrijednosti CWSIa. Mjerenja na uzorcima pod visokim vodenim stresom su se pokazala problematična, te bi za precizniju analizu takvih uzoraka trebalo koristiti filter koji bi preciznije identificirao samo površine koje predstavljaju listove.

Dobivenim rezultatima mjerenja pokazano je da je bila opravdana pretpostavka da se korištenjem metoda i pristupa razvijenih pri mjerenju na uzorku paprike mogu dobiti relevantni rezultati i na drugim vrstama presadnica. Tijekom ovog snimanja je pak primijećeno da su biljke pod visokim vodenim stresom problematične za snimanje, a što nije bilo u tolikoj mjeri primjetno na uzorku paprike jer tamo nisu uspješno ostvareni uvjeti visokog vodnog stresa za cijeli promatrani dio uzorka. To znači da u praktičnoj primjeni ova metoda ima ograničenje da ne

može dobro raditi u slučaju da se snimaju biljke kod kojih je venuće već nastalo. Ipak, u realnom slučaju (za koji bi se koristio ovakav način upravljanja navodnjavanjem) je ionako neprihvatljivo da venuće ikada počne, te bi se s navodnjavanjem počelo u uvjetima vodnog stresa u kojima termografska kamera još uvijek može davati pouzdane rezultate.

Mikorizirani uzorci nisu pokazali značajnu razliku u odnosu na nemikorizirane uzorke. Niti vrijednosti temperature lista, niti dobivene vrijednosti CWSIa mikorizirane biljke nisu pokazale trend kojime bi odudarao od onoga za nemikorizirane. Može se zaključiti da na osnovu dobivenih vrijednosti temperatura i CWSI nema dokaza koji bi govorili u korist primjene mikorize kao metode smanjivanja temperature lista ili CWSIa biljke izložene vodnom stresu.

Da bi se termografskim snimanjem dobivena vrijednost CWSIa mogla praktično primijeniti ista se mora moći povezati pouzdanim modelom s vodnim potencijalom lista promatrane biljke. U tu svrhu je, uz korištenje rezultata dobivenih i prikazanih u ovom poglavlju, u sljedećem poglavlju proveden detaljan razvoj modela koji opisuje vezu između mjerenih vrijednosti CWSI i LWP na promatranom uzorku.

6. RAZVOJ MODELA VEZE IZMEĐU CWSI I LWP ZA RAJČICU

Mjerenjima iz prethodnog poglavlja su dobiveni rezultati na osnovu kojih je moguće razviti model koji bi predviđao vodni potencijal lista presadnice rajčice u odnosu na izmjereni indeks vodnog stresa krošnje. Ovaj model je razvijen po uzoru na modele koji su opisani u poglavlju 2. Da bi se mogao dobiti što pouzdaniji model provedena je analiza za više mogućih načina interpretacije mjerenih vrijednosti i referentnih temperatura.

6.1. Model za potpuno automatsku obradu

Prvi, i najjednostavniji model se oslanja u potpunosti na termograme za određivanje CWSIa. U njemu se cijeli termogram analizira fiksnim algoritmom koji ne uključuje vizualnu identifikaciju dijelova termograma na kojima možda nisu listovi biljke nego tlo, posude ili okoliš. Ovdje se radi pretpostavka da je krošnja dovoljno gusta da nema utjecaja tla, ni drugih eventualnih vanjskih elemenata poput posuda ili stupova na termogramu. Ovo podrazumijeva da se tijekom snimanja mora napraviti termogram odgovarajuće kvalitete na kojemu neće biti značajnih područja na kojima nisu listovi.

CWSI se računa prema jednadžbi (4). Temperature se određuju na dva različita načina. Prvi je da se izračuna prosječna temperatura termograma i usvoji kao izmjerena temperatura krošnje. Drugi je da se kao temperatura krošnje koristi medijan temperature na termogramu, koji bi u dobro izvedenom termogramu trebao odgovarati upravo prosječnoj temperaturi samo listova u krošnji. Suha referentna temperatura se određuje prema jednadžbi (5). Vlažna referentna temperatura se određuje na dva načina, kao minimalna vrijednost temperature na termogramu, odnosno kao vrijednost temperature od koje je manje točno 10% izmjerenih temperatura na termogramu. Ovime se dobivaju četiri moguće kombinacije za analizu.

Analiza je provedena korištenjem regresijske analize. Regresijska analiza se koristi za analizu ovisnosti niza slučajnih varijabli Y o nekoj nezavisnoj varijabli X , odnosno kontroliranoj, varijabli. U ovom slučaju LWP predstavlja mjerene vrijednosti slučajnih varijabli Y , a CWSI vrijednosti odgovarajuće nezavisne varijable X .

Ovaj matematički model je u općem slučaju iskazan jednadžbom (23):

$$Y_i = f(X_i) + \varepsilon_i \quad (23)$$

Pri čemu je $f(X_i)$ realna funkcija varijable X_i . U slučaju jednodimenzijskog regresijskog modela vrijednosti reziduala ε_i predstavljaju šum modela za koji vrijedi da mu je očekivanje jednako nuli, a varijanca konstantna. Ovo sve vrijedi za set mjerenih vrijednosti i od 1 do n . Ako se pretpostavi da je funkcijska veza između mjerenih podataka pravac, tada se gornja jednačba može pojednostaviti u oblik dan u jednačbi (24):

$$Y_i = A + B * X_i + \varepsilon_i \quad (24)$$

Ovako dobiven pravac se naziva regresijski pravac, a veličina B se naziva koeficijentom regresije. Iznosi A i B se zatim dobivaju primjenom metode najmanjih kvadrata, pri čemu se za konačne vrijednosti veličina A i B usvajaju one vrijednosti pri kojima je suma kvadrata reziduala ε_i najmanja. Korijen iz ove vrijednosti predstavlja srednje kvadratno odstupanje modela.

Da bi se opisalo koliki je dio promjena u mjerenim vrijednostima zavisne varijable objašnjen dobivenim modelom, tj. da bi se ispitala jakost modela, koristi se koeficijent determinacije R^2 . On predstavlja omjer standardnog odstupanja modela s umnoškom standardnih odstupanja varijabli X i Y . Drugim riječima on govori koliko rasipanja izlaznih podataka potječe od funkcijske ovisnosti korištene u regresijskoj analizi, a koliko otpada na rezidualno ili neobjašnjeno rasipanje. Vrijednosti R^2 jednaka 0 znači da se vrijednost varijable Y ne može pretpostaviti s obzirom na varijablu X . Vrijednost R^2 od 1 znači da odabrani model savršeno uspješno opisuje vezu između ovih varijabli.

Uz koeficijent determinacije koristi se i p-vrijednost. Ona predstavlja vjerojatnost da su za mjerenje slučajno uzeti samo povoljni uzorci. Drugim riječima ona govori kolika je vjerojatnost da je dobivena korelacija posljedica toga što je slučajno izabran uzorak za koji korelacija vrijedi, ali koji nije reprezentativan u općem slučaju i korelacija dobivena na tom uzorku neće vrijediti za neki drugi proizvoljni uzorak. Obično se smatra da je nađena korelacija statistički značajna kada je p-vrijednost manja od 5%. U tom slučaju je vjerojatnost da je nađena korelacija produkt slučajno nereprezentativnog uzorka manja od 5%. [10]


Za dobivene vrijednosti temperature je u odnosu na izmjerene vrijednosti vodnog potencijala prikazane u prethodnom poglavlju napravljena linearna regresija kojom je dobiven model koji jednoznačno opisuje njihovu vezu. Relevantnost dobivenog modela je ocjenjivana prema njegovim vrijednostima R^2 i p . Pri tome se svi rezultati kojima je p veći od 0,05 odbacuju, a odbacuju se i svi modeli kojima je R^2 manji od 0,65, u skladu s primjerima koji su prikazani u poglavlju 2.

6.1.1. Prosječna temperatura kao ϑ_i i minimalna temperatura kao ϑ_{wet}

Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (25):

$$LWP = -2,012 * CWSI - 0,268 \quad (25)$$

Pri tome su dobivene vrijednosti $R^2 = 0,76$ i $p = 0,005$, što pokazuje da postoji statistički značajna korelacija između na ovaj način obrađenih podataka. Grafički prikaz ovih rezultata dan je na slici 50.



Slika 50. Veza CWSI-LWP za slučaj 6.1.1.


Iz gornjeg dijagrama vidljivo je da su neke mjerene vrijednosti izvan intervala pouzdanosti modela, te da iako model pokazuje dobru korelaciju ipak ima i značajno srednje kvadratno odstupanje od 0,223 MPa, što je posebno zamjetno kod manjih vrijednosti CWSIa, odnosno LWPa.

6.1.2. Prosječna temperatura kao ϑ_i i $\vartheta_{10\%}$ kao ϑ_{wet}

Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (26):

$$LWP = -2,248 * CWSI - 0,267 \quad (26)$$

Pri tome su dobivene vrijednosti $R^2 = 0,80$ i $p = 0,003$, što pokazuje da postoji bolja i statistički značajnija korelacija nego u prethodnom slučaju. Grafički prikaz ovih rezultata dan je na slici 51.



Slika 51. Veza CWSI-LWP za slučaj 6.1.2.


Iako je dobivena bolja korelacija i dalje postoji problem rasipanja vrijednosti pri nižim vrijednostima CWSIa, odnosno LWPa. Srednje kvadratno odstupanje je nešto manje u ovom slučaju, no i dalje iznosi relativno visokih iznosi 0,203 MPa.

6.1.3. Medijan temperature kao ϑ_i i minimalna temperatura kao ϑ_{wet}

Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (27):

$$LWP = -1,942 * CWSI - 0,354 \quad (27)$$

Pri tome su dobivene vrijednosti $R^2 = 0,67$ i $p = 0,013$, što je značajno slabija korelacija nego što je nađena u prethodnom slučaju. Grafički prikaz ovih rezultata dan je na slici 52.



Slika 52. Veza CWSI-LWP za slučaj 6.1.3.


Srednje kvadratno odstupanje u ovom slučaju iznosi 0,260 MPa što je više nego u prethodnim slučajevima. Iz svega navedenog se može vidjeti da se ovaj pristup analizi termograma nije pokazao opravdanim u odnosu na prethodne, te da ga se u daljnjim razmatranjima može preskočiti.

6.1.4. Medijan temperature kao ϑ_i i $\vartheta_{10\%}$ kao ϑ_{wet}

Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (28):

$$LWP = -2,245 * CWSI - 0,351 \quad (28)$$

Pri tome su dobivene vrijednosti $R^2 = 0,71$ i $p = 0,009$, što pokazuje da postoji bolja i statistički značajnija korelacija nego u prethodnom slučaju, no i dalje lošija nego u oba slučaja s prosječnim vrijednostima. Grafički prikaz ovih rezultata dan je na slici 53.



Slika 53. Veza CWSI-LWP za slučaj 6.1.4.


Srednje kvadratno odstupanje u ovom slučaju iznosi 0,243 MPa što je nešto manje nego u prethodnom slučaju. Iz svega ovoga je razvidno da metoda koja koristi $\vartheta_{10\%}$ za vlažnu referentnu temperaturu daje bolju korelaciju, kako je i sugerirano u ranijim radovima. Također se može zaključiti da korištenje medijana temperature nije opravdano, te da je potrebno koristiti prosječnu temperaturu da bi se postigla korelacija podataka.

6.2. Model za potpuno automatsku obradu sa selekcijom piksela

Prethodni model je podrazumijevao da su napravljeni termogrami sadržavali samo promatrane krošnje, što u stvarnosti nije slučaj. Stoga se može primjenom jednadžbe (12) pokušati poboljšati kvaliteta obrade podataka tako da se uklone svi oni pikseli koji ne sadrže listove. Treba napomenuti da se ova metoda u oslanja na raniji rad Merona prikazan u dijelu 2.4. [5] U prvoj iteraciji su stoga preuzete granične vrijednosti navedene u tom radu. Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (29):


$$LWP = -2,400 * CWSI - 0,248 \quad (29)$$

Pri tome su dobivene vrijednosti $R^2 = 0,78$ i $p = 0,004$, što pokazuje da je korelacija lošija nego u modelu 6.1.2., no bolja nego u 6.1.1., 6.1.3. i 6.1.4. Grafički prikaz ovih rezultata dan je na slici 54.



Slika 54. Veza CWSI-LWP za slučaj 6.2. prema Meronu


Srednje kvadratno odstupanje u ovom slučaju iznosi 0,211 MPa. Primjetno je da se uporabom graničnih temperatura koje predlaže Meron nije postiglo povećanje korelacije u odnosu na model 6.1.2. Da bi se otkrio razlog tome potrebno je provjeriti kako se mijenja korelacija s promjenom graničnih temperatura. Povećanjem gornje granične temperature se korelacija mijenjala na način prikazan na dijagramu na slici 55. asimptotski prema vrijednostima dobivenima u modelu 6.1.2.



Slika 55. Promjena stupnja korelacije s porastom gornje granične vrijednosti

Očito je da se model raspada u području graničnih vrijednosti od 2 do 4 °C iznad temperature okoliša. Vrijednost od 7 °C koju predlaže Meron pada u područje u kojem se dodatnim povećanjem gornje granične temperature dodatno povećava korelacija modela. To znači da postoje temperature listova koje su i za više od 7 °C veće od temperature okoliša. Na gornjem dijagramu se pojavljuju relativno povoljne vrijednosti R^2 i p za granične vrijednosti temperatura od 2 °C iznad okolišnih, no ti rezultati zapravo ne ukazuju na to da postoji dobra korelacija između CWSIa i LWPa u tom slučaju, nego da su zbog toga što su skoro sve vrijednosti nulirane iščezle točke za sve nenavodnjavane uzorke.

Promjenom donje granične temperature ne dolazi do značajne promjene u korelaciji modela. Grafički prikaz ovog ponašanja je dan na slici 56.




Slika 56. Promjena stupnja korelacije sa smanjenjem donje granične vrijednosti

Vidljivo je da promjena donje granične temperature nema značajan utjecaj na stupanj korelacije modela. Za donje granične vrijednosti manje od temperature okoliša umanjene za 3 °C nema promjene stupnja korelacije. Jedina razlika se može primijetiti kod korištenja donje granične vrijednosti jednake temperaturi okoliša umanjenoj za 2 °C, no i tada je ta razlika malena. Pretpostavlja se da je razlog tome što su temperature najhladnijih listova bile niže ili barem usporedive s najnižim temperaturama ostalih objekata u pregrijanom zaštićenom prostoru.

Može se zaključiti da je korištenje Meronove metode na ovakvim termogramima nepotrebno jer se njime ne dobiva povećanje korelacije modela, nego se krivim izborom graničnih vrijednosti može i smanjiti. Analizom temperatura zabilježenih na termogramima i vizualnom identifikacijom njihovih lokacija može se zaključiti da se veći dio visokih temperatura na termogramima javlja u samim krošnjama. Na snimkama u pravilu nema velikih područja koja se odnose na okoliš, tlo ili posude, te u potpuno automatiziranom postupku selekcije na osnovi temperature dolazi do problem odbacivanja previše piksela koji sadrže listove. Ovo ne znači da Meronova metoda nije ispravna, nego samo da ju nema smisla primjenjivati u slučajevima kada termogrami ne sadrže značajan udio tla i/ili drugih objekata.

6.3. Model s grubom ručnom selekcijom piksela

Kada su istražene potpuno automatske opcije analize termograma potrebno je napraviti ručnu analizu kojom bi se moglo validirati opravdanost korištenja automatskih, tj. prikazati koliki je gubitak preciznosti napravljen time što se promatra cijeli termogram umjesto specifičnih vizualno odabranih dijelova. U tu svrhu će biti korištene dvije metode: gruba i fina. U gruboj metodi će se sa svakog od termograma odabrati jedna reprezentativna površina za koju se pretpostavlja da ne sadrži značajne vanjske utjecaje ili piksele koji prikazuju išta drugo osim listova krošnje. Prikaz procesa selekcije dan je na slici 57.




Slika 57. Proces grube selekcije područja termograma

U samoj obradi se maska sprema kao zasebna bitmapa, uz bojanje prozora u bijelo da bi se izbjeglo brisanje vrijednosti temperatura iz eventualnih potpuno crnih piksela u njemu tijekom obrade. Taj filter se zatim učitava u softver MatLab R2016a i sve temperature koje odgovaraju zacrnjenim pikselima se nuliraju. Time se dobiva matrica temperatura koja bi trebala odgovarati pretpostavkama iz prethodnog odlomka. Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (30):

$$LWP = -2,135 * CWSI - 0,352 \quad (30)$$

Pri tome su dobivene vrijednosti $R^2 = 0,80$ i $p = 0,003$, što su identične vrijednosti kao i za slučaj 6.1.2. Ovo je posebno zanimljivo kada se uzme u obzir da je korištena metoda analize identična onoj u 6.1.2., jer sugerira da je odabrani dio jednako reprezentativan kao i termogram u cjelini. Grafički prikaz ovih rezultata dan je na slici 58.




Slika 58. Veza CWSI-LWP za slučaj 6.3.

Srednje kvadratno odstupanje u ovom slučaju iznosi 0,200 MPa što je zanemarivo manje nego u slučaju 6.1.2. Ovo ukazuje da je grubom selekcijom ostvarena jednaka korelacija vrijednosti CWSIa s mjerenim vrijednostima LWPa u odnosu na slučaj kada se istom metodom analizira cijeli termogram. Vjerojatan razlog ove razlike je to što se prilikom grube selekcije kao logično i očito područje izbora nametnula sredina uzorka, a ona je očito jednako reprezentativna kao i cijeli uzorak. Pretpostavlja se da je isključenjem rubnih listova skupa s rubnim područjima koja nisu dio uzorka izgubljen važan dio podataka koji bi dodatno povećao korelaciju kada bi bio uključen.

Iz ovoga je jasno da metoda grube selekcije funkcionira jednako dobro kao i automatizirana analiza cijelog termograma. Ipak, ne treba a priori otpisati ovu metodu kao nepotrebnu komplikaciju automatske analize. Prvo je potrebno provjeriti utjecaj rubnih listova na korelaciju. Iz tog razloga je odlučeno da se ponovno provede analiza po ovoj metodi uz grublju selekciju promatranog područja. U novom pokušaju će na svim termogramima biti označeno cijelo područje uzorka i izbacit će se samo eventualni dijelovi koji sadrže EPS panele, posude ili okolno tlo. Pri tome će prozor i dalje ostati pravokutnik i neće se provoditi finija selekcija koja pripada u finu metodu i koja će biti analizirana u potpoglavlju 6.4.

6.3.1. Ponovljena iteracija grube metode

Prikaz promijenjenog procesa selekcije i razlika u odnosu na početni termogram i selekciju u prethodnoj iteraciji dan je na slici 59.




Slika 59. Izmijenjeni proces grube selekcije područja termograma

Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (31):

$$LWP = -2,361 * CWSI - 0,284 \quad (31)$$

Pri tome su dobivene vrijednosti $R^2 = 0,82$ i $p = 0,002$, što je bolji rezultat nego u prethodnoj iteraciji. Ova razlika nije ogromna, ali ukazuje na to da smetnje na rubu termograma utječu na analizu. Grafički prikaz ovih rezultata dan je na slici 60.




Slika 60. Veza CWSI-LWP za slučaj 6.3.1.

Srednje kvadratno odstupanje u ovom slučaju iznosi 0,196 MPa. Iz svega ovoga je razvidno da se metodom grube selekcije piksela postiže mala prednost nad potpuno automatskom analizom termograma uz uvjet da su termogrami dovoljno precizno napravljeni i ne uključuju značajna područja bez krošnji. Ova prednost je vjerojatno veća za lošije snimke.

6.4. Model s finom ručnom selekcijom piksela

Kako se pokazalo da gruba selekcija daje malo povećanje korelacije u odnosu na automatsku selekciju na dobro snimljenim termogramima, tada se kao idući korak postavlja opcija da se napravi fina selekcija piksela. Na ovaj način bi se moglo s većom točnošću ukloniti sve piksele koji ne sadrže listove i osigurati da se u obzir uzimaju samo temperature izmjerene na listovima rajčice. Proces označavanja piksela je istovjetan onome u poglavlju 6.3. Selekcija piksela je bila vizualna, a s obzirom na to da ne postoji paralelna slika u vidljivom spektru napravljena iz istog kuta onda je proces bio ograničen razlučivosti na termogramu. Prikaz procesa selekcije dan je na slici 61.




Slika 61. Proces fine selekcije područja termograma

Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (32):

$$LWP = -2,386 * CWSI - 0,285 \quad (32)$$

Pri tome su dobivene vrijednosti $R^2 = 0,83$ i $p = 0,002$, što je marginalno bolja korelacija nego što je dobivena u prethodnim slučajevima. Grafički prikaz rezultata dan je na slici 62.




Slika 62. Veza CWSI-LWP za slučaj 6.4.

Srednje kvadratno odstupanje u ovom slučaju iznosi 0,189 MPa. Može se zaključiti da je finom selekcijom malo poboljšana korelacija vrijednosti CWSIa izračunatih iz termograma i mjerenih vrijednosti LWPa. Moguće je da bi se preciznijim odabirom piksela ova korelacija mogla dodatno povećati, no nažalost bez fotografije u vidljivom spektru nije moguće s većom preciznošću razlučiti između piksela koji prikazuju tlo, posude ili EPS panele i piksela koji prikazuju listove i stabljike na termogramu. U ručnoj finoj selekciji je na termogramima puno lakše bilo identificirati piksele koji su predstavljali EPS panele ili posude, dok su hladniji pikseli tla bili teško razlučivi od listova, što je možda utjecalo na to da se veći broj takvih piksela uzeo u obzir. Ovo je pogotovo točno za uzorke koji su dobro navodnjavani i stoga imaju listove i tlo niže temperature.

6.5. Model s referentnim temperaturama pripremljenih listova

Idući korak u razvoju modela je razvoj modela koji referentne temperature uzima iz posebno pripremljenih listova. Kao što je opisano u poglavlju 4. tijekom mjerenja zadnjeg dana u mjerenje su uključeni i posebno pripremljeni referentni listovi. U svrhu ocjene opravdanosti ovakvog pristupa usporedit će se dva modela. Jedan dobiven metodom opisanom u 6.1.2., a drugi korištenjem referentnih temperatura izmjerenih na referentnim listovima. S obzirom na to da su mjerenja s referentnim listovima dostupna samo za 18. svibnja 2017., tada će broj mjernih točaka na osnovu kojih će biti razvijen ovaj model biti manji nego što je bio u potpoglavlju 6.1.2. jer su tamo promatrani rezultati oba dana. Slika 63. prikazuje referentne listove na termogramima koji su obrađivani.





Slika 63. Prikaz referentnih listova na termogramima

Na gornjoj slici su listovi premazani vazelinom označeni crvenom bojom, dok su oni koji su bili navlaženi vodom označeni plavom bojom. U obradi termograma je korišten isti pristup kao i u potpoglavljima 6.3. i 6.4. Referentni list je bio označen bijelom bojom, a ostatak slike je bio zacrnjen. Ta slika je zatim korištena kao filter prema kojemu su nulirane sve temperature na termogramu osim onih na željenom listu.

Tijekom provedbe analize dobivene su negativne vrijednosti CWSIa jer se pokazalo da, suprotno očekivanjima, navlaženi listovi nisu bili postigli nižu temperaturu. Pregled vrijednosti dobivenih tijekom analize dan je u tablici 5.

Tablica 5. Pregled vrijednosti u analizi pod 6.5.

Grupa	$\vartheta_{\text{canopy}}$	ϑ_{wet}	ϑ_{dry}	CWSI	LWP
-	°C	°C	°C	-	MPa
Mikoriza navodnjavano	21,1	20,0	22,2	0,487	-0,770
Bez mikorize navodnjavano	21,3	21,4	23,1	-0,024	-0,470
Bez mikorize nenavodnjavano	25,3	26,4	28,0	-0,734	-1,250
Mikoriza nenavodnjavano	25,9	26,7	27,8	-0,742	-1,550


Očito je da je problem nastao s vlažnom referentnom temperaturom. Više je mogućih razloga zašto se ovo dogodilo. Najvjerojatniji razlog je da listovi nisu bili pravilno pripremljeni. Ako navlaživanje nije bilo dostatno ili listovima nije bilo ostavljeno dovoljno vremena da se ohlade nakon navlaživanja, tada bi ovakvi rezultati bili očekivani.

Ovaj ishod ilustrira problematičnost u široj primjeni ovog pristupa, koju navode i raniji autori. Cijelo mjerenje ovisi o tome koliko je dobro pripremljen referentni list, a ispravnost mjerenja se tek može pouzdano odrediti tijekom analize nakon snimanja.

Provedbom linearne regresije za ove rezultate dobivena je veza CWSIa i LWPa dana jednadžbom (33):

$$LWP = 0,636 * CWSI - 0,849 \quad (33)$$

Pri tome su dobivene vrijednosti $R^2 = 0,62$ i $p = 0,213$, koje dodatno ukazuju da je došlo do greške u mjerenju vlažne referentne temperature, odnosno da su referentni listovi bili nepravilno pripremljeni. Grafički prikaz ovih rezultata dan je na slici 64.



Slika 64. Veza CWSI-LWP za slučaj 6.6.


Valja primijetiti da je skala za CWSI na gornjem dijagramu drugačija nego na ostalim dijagramima u ovom poglavlju, jer je morala biti produžena do -1 da bi se mogli prikazati dobiveni rezultati. Jasno je da ovakve rezultate nema smisla uspoređivati s ostalim rezultatima dobivenima u ovom poglavlju nego ih se mora odbaciti.

6.6. Model za mikorizirane biljke

Korišteni uzorci su se međusobno razlikovali po tome što je pola uzoraka bilo mikorizirano, a pola nije. Uz uporabu metode opisane u potpoglavlju 6.1.2. napravljena je zasebna analiza ovih dviju skupina uzoraka. Ovakva selekcija je dodatno ograničila broj točaka na osnovu kojih se mogla napraviti linearna regresija, no povećanje broja uzoraka bi zahtijevalo značajniju investiciju. Očekuje se da se veće razlike, ako postoje, mogu primijetiti i na ovakvom uzorku. Provedbom linearne regresije za ovaj slučaj dobivena je veza CWSIa i LWPa dana jednadžbom (34):

$$LWP = -2,191 * CWSI - 0,341 \quad (34)$$

Pri tome su dobivene vrijednosti $R^2 = 0,84$ i $p = 0,083$. Ovo znači da iako je dobivena dobra korelacija postoji značajna mogućnost da je ona proizvod slučajnog preklapanja koja je posljedica maloga uzorka. Grafički prikaz ovih rezultata dan je na slici 65.



Slika 65. Veza CWSI-LWP za slučaj 6.6.


Srednje kvadratno odstupanje u ovom slučaju iznosi 0,223 MPa. Iz dijagrama je vidljivo da je veza CWSI-LWP veoma ovisna o samo jednom mjerenju, i to onome za nenavodnjavani uzorak, napravljenom 18.05. To znači da svaka mjerna nesigurnost tog mjerenja može prouzrokovati velika odstupanja u dobivenom modelu od stvarnih vrijednosti. Ipak, dobiveni model nije značajno različit od onih dobivenih za cijeli uzorak. Da bi se moglo sa sigurnošću potvrditi da je dobivena veza statistički značajna, a ne samo slučajan ishod zbog jednog mjerenja, bilo bi potrebno ponoviti mjerenje na većem uzorku.

6.7. Model za nemikorizirane biljke

Isti postupak kao i u prethodnom potpoglavlju primijenjen je i na nemikoriziranim uzorcima. Veza CWSIa i LWPa dobivena provedbom linearne regresije dana je izrazom (35):

$$LWP = -2,199 * CWSI - 0,219 \quad (35)$$

Pri tome su dobivene vrijednosti $R^2 = 0,76$ i $p = 0,128$. Ovo znači da iako je dobivena dobra korelacija postoji značajna mogućnost da je ona proizvod slučajnog preklapanja koja je posljedica maloga uzorka. Grafički prikaz ovih rezultata dan je na slici 66.



Slika 66. Veza CWSI-LWP za slučaj 6.6.

Srednje kvadratno odstupanje u ovom slučaju iznosi 0,245 MPa. Iz dijagrama je vidljivo da je veza CWSI-LWP primarno ovisi o mjerenju za nenavodnjavani uzorak napravljenom 18.05., kao što je bio slučaj i kod modela za mikorizirane biljke. S obzirom na to da je korišten identičan broj uzoraka u oba slučaja onda su ovakvi slični rezultati očekivani. Jedino moguće rješenje kojime bi se mogla potvrditi stvarna statistička relevantnost modela je da se napravi istraživanje koje bi uključivalo veći broj mjernih točki za oba uzorka.

6.8. Analiza razvijenih modela

Vidljivo je da je u svim razvijenim modelima osim 6.1.3. i 6.2. pronađena dobra korelacija promatranih vrijednosti CWSI i LWP. Ostali modeli, iako slični su davali različite vrijednosti koeficijenta i korelacije. Da bi se mogao odabrati optimalni model potrebno je napraviti usporedbu svih modela. Pregled ovih modela dan je u tablici 6. Ovdje su koeficijenti linearne regresije označeni s A i B.

Tablica 6. Pregled razvijenih modela

Model	A	B	R ²	p-val	RMSEr
-	-	MPa	-	-	MPa
6.1.1.	-2,012	-0,268	0,76	0,005	0,223
6.1.2.	-2,248	-0,267	0,80	0,003	0,203
6.1.3.	-1,942	-0,354	0,67	0,013	0,260
6.1.4.	-2,245	-0,351	0,71	0,009	0,243
6.2.	-2,400	-0,248	0,78	0,004	0,211
6.3.	-2,135	-0,352	0,80	0,003	0,200
6.3.1.	-2,361	-0,284	0,82	0,002	0,196
6.4.	-2,386	-0,285	0,83	0,002	0,189
6.5.	0,636	-0,849	0,62	0,213	0,364
6.6.	-2,191	-0,341	0,84	0,083	0,223
6.7.	-2,199	-0,219	0,76	0,128	0,245

Najveću korelaciju očekivano postiže model 6.4. u kojemu su područja za analizu ručno birana finom metodom. U njemu je postignuta korelaciju za ukupni set podataka s $R^2 = 0,84$ i $p = 0,002$. On također ima i najmanje odstupanje modela od samo 0,189 MPa. Modeli 6.3. i 6.3.1. su pokazali usporedivu, no ipak (neznatno) manju korelaciju u odnosu na model 6.4. Pretpostavka je da bi se preciznijim odabirom piksela u ručnim metodama, prvenstveno korištenjem fotografija za usporedbu, mogla dodatno poboljšati korelacija u tim modelima.

Modeli 6.1.3., 6.1.4. su pokazali nedovoljnu razinu korelacije u usporedbi s ostalim modelima razvijenim uz korištenje ukupnog seta podataka za oba dana mjerenja. Model 6.2. nije pokazao bolju korelaciju od modela 6.1.2., no ipak treba napomenuti da je model 6.2. uspješno korišten u ranijim radovima drugih autora, te da njegovo odbacivanje u ovom slučaju ne znači da nije uopće primjenjiv, nego da u promatranom slučaju nije bio koristan. Kao što je i ranije rečeno, razlog tome je vjerojatno u činjenica da je u ovom istraživanju korištena različita vrsta uzorka u kojoj nije bilo značajnih područja tla ili drugih objekata u vidnom polju kamere, pa su odbacivanjem vršnih vrijednosti odbacivani pikseli koji sadrže listove.

Model 6.1.2. se ističe među automatiziranim modelima jer postiže najveću korelaciju za ukupni set podataka s $R^2 = 0,80$ i $p = 0,003$. On također ima i odstupanje modela od samo 0,203 MPa, što je usporedivo s odstupanjima ručnih modela. Može se zaključiti da u slučajevima kada termogrami ne sadrže veliku količinu neželjenih područja je automatska obrada cijelog termograma podjednako značajna kao i obrada specifično odabranih piksela. Ipak potrebno se osvrnuti i na njegove nedostatke. Ovaj model stavlja teret pouzdanosti na termografista, jer kao ulazni podatak očekuje termograme zadovoljavajuće kvalitete u kojima nema značajne zastupljenosti piksela koji ne predstavljaju lišće rajčice.

Vrijednosti vlažne referentne temperature dobivene iz referentnih listova u modelu 6.5. su se pokazale previsokima, te se zaključuje da je došlo do greške u pripremi ovih listova. S obzirom na to je dobiveni model značajno različit od svih ostalih, te pokazuje statistički neznčajnu korelaciju. Zbog toga ga nije moguće niti smisleno uspoređivati s drugim razvijenim modelima.

Modeli 6.6. i 6.7. koji modeliraju ponašanje mikoriziranih i nemikoriziranih uzoraka su slični. Razlika u nagibu regresijske krivulje je tako tek na trećoj decimali. Pomak krivulje je ipak nešto veći za model 6.6., a isti model ima i veći R^2 . To bi sugeriralo da mikorizirani uzorak ima veći LWP pri jednakom CWSIu, no u oba slučaja je ipak korelacija nedovoljno značajna ($p = 0,083$ i $p = 0,128$) da bi se iz njih mogli izvoditi konkretni statistički značajni zaključci. Ovo je posljedica ograničenog uzorka u oba slučaja.

7. ZAKLJUČAK

Provedena su mjerenja i analiza na dva različita uzorka. Prvo je na uzorku paprike provedeno inicijalno istraživanje tijekom kojega je razvijena metoda mjerenja i obrade podataka. Tijekom mjerenja je došlo do probijanja vode kroz paletu, te je nenavodnjavani uzorak postao nereprezentativan. Zbog toga su dobivene vrijednosti temperature lista i CWSI koje nisu odgovarale onima koje su očekivane prema fizikalnom ponašanju biljke pod vodnim stresom. No iako je tijekom ovog mjerenja došlo do problema sa stvaranjem vodnog stresa odgovarajućem uzorku, ipak je dobiveno vrijedno iskustvo u provedbi istraživanja koje je spriječilo da do takvih grešaka dođe u glavnom istraživanju na presadnicama rajčice.

Drugi promatrani uzorak je bila industrijska rajčica na kojoj je uspješno provedeno mjerenje temperatura termoparovima i termografijom, te su izbjegnuti problemi koji su se dogodili pri mjerenju na paprikama. Uporabom metode razvijene pri istraživanju na paprikama dobiveni su rezultati temperature i CWSIa koji su odgovarali očekivanima iz teoretskog poznavanja ponašanja biljke pod vodnim stresom. Osim toga je na paprikama provedeno i mjerenje vodnog potencijala koje je omogućilo razvoj modela veze između CWSIa i LWPa za promatrani uzorak, a provedeno je i mjerenje fotosinteze i otvorenosti puči. Ova dva posljednja mjerenja nisu uspjela jer je venuće već počelo u trenutku mjerenja.

Najveće ograničenje pokusu i razvoju modela je bilo mjerenje vodnog potencijala lista. S obzirom na to da je ono destruktivno mjerenje koje zahtjeva dostupnost odgovarajućih listova koji se mogu odsjeći tada je bio moguć samo ograničen broj mjerenja LWPa na istom uzorku. To znači da bi istraživanje koje bi htjelo postići veći broj mjernih točaka moralo imati značajno veći broj biljaka po pojedinom uzorku. Osim toga se uklanjanjem većeg broja listova bi se utjecalo na sam uzorak, što dodatno ograničava broj listova koji se može koristiti za ovo mjerenje.

Prilikom izrade modela veze između CWSIa i LWPa uspoređivane su potpuno automatska metoda u kojoj se u obzir uzima cijeli termogram i metode s ručno primijenjenim filtrima različite kvalitete. Pokazalo se da automatska metoda daje usporedivo dobre rezultate kao i metode s ručnom obradom, no također zahtjeva termograme visoke kvalitete kao ulazne podatke. Tako primjerice pri izračunu CWSIa kroz oba dana nije bilo moguće koristiti ovu metodu jer su termogrami bili nedovoljno precizno namješteni u svim mjerenjima. Može se zaključiti da bi preduvjet za primjenu automatske metode bila izrada dovoljno kvalitetnih

termograma, a koja bi bila moguća ukoliko bi se koristila kamera montirana na vodicama i zaštićeni prostor s primjereno ravnima podovima i prostorom za postavljanje kamere.

Metoda odbacivanja dijela piksela bez vizualne analize koju je predložio Meron se u ovom slučaju nije pokazala opravdanom jer su temperature listova i okoliša bile previše slične, te je odbacivanjem piksela isključivo na osnovu temperature dolazilo do odbacivanja prevelikog broja piksela koji su sadržavali temperature listova. Ipak, moguće je da bi i ovdje njena primjena bila opravdana kada bi termogrami sadržavali veći udio tla i ostalih objekata.

Nije pronađen statistički značajan utjecaj mikorize na temperaturu i CWSI biljke izložene vodnom stresu. Zabilježene razlike su bile vrlo male, te se na osnovu njih ne može opravdati povećano ulaganje potrebno da bi se proveo postupak mikorizacije. Ipak, promatrani uzorci nisu bili dostatno veliki da bi se sa sigurnošću moglo zaključiti da su dobiveni rezultati statistički značajni, te je stoga otvorena mogućnost da bi istraživanjima na većem uzorku se mogla dobiti i nekakva razlika između mikoriziranih i nemikoriziranih biljaka.

U idućem koraku bilo bi potrebno provesti ponovljeno istraživanje na većem uzorku u kojemu bi se mjerene vrijednosti LWPa i CWSIa uspoređivale s vrijednostima LWPa izračunatima iz mjerenih vrijednosti CWSIa prema ovdje razvijenom modelu. Tada bi se s obzirom na primijećena odstupanja i novi set podataka mogao revidirati model s ciljem da se poveća stupanj korelacije.

Konačno, da bi ovako dobiven model bio praktično primjenjiv bilo bi potrebno razviti rješenje za sustav automatske provedbe termogramskog snimanja u zaštićenom prostoru, te softverski paket koji bi uz korištenje ovoga modela mogao omogućiti upravljanje sustavom navodnjavanja.

LITERATURA

- [1] Andrassy, M., Boras, I., Dović, D., Švaić, S.: Infracrvena termografija: Izobrazba termografera, Zagreb, 2007.
- [2] Cohen, Y., Alchanatis, V., Meron, M., Saranga, Y., Tsipris, J.: Estimation of leaf water potential by thermal imagery and spatial analysis, *Journal of Experimental Botany*, Vol. 56, No. 417, pp. 1843–1852, 2005.
- [3] Grant, O. M., Tronina, L., Jones, H. G., Chaves, M. M.: Exploring thermal imaging variables for the detection of stress responses in grapevine under different irrigation regimes, *Journal of Experimental Botany*, Vol. 58, No. 4, pp. 815–825, 2007.
- [4] Alchanatis, V., Cohen, Y., Cohen, S., Moller, M., Sprinstin, M., Meron, M., Tsipris, J., Saranga, Y., Sela, E.: Evaluation of different approaches for estimating and mapping crop water status in cotton with thermal imaging, *Precision Agriculture*, 2010.
- [5] Meron, M., Tsipris, J., Orlov, V., Alchanatis, V., Cohen, Y.: Crop water stress mapping for site-specific irrigation by thermal imagery and artificial reference surfaces, *Precision Agriculture*, 2010.
- [6] Grant, O. M., Davies, M. J., James, C. M., Johnson, A. W., Leinonen, I., Simpson, D. W.: Thermal imaging and carbon isotope composition indicate variation amongst strawberry (*Fragaria×ananassa*) cultivars in stomatal conductance and water use efficiency, *Environmental and Experimental Botany*, 2011.
- [7] Cohen, Y., Alchanatis, V., Sela, E., Saranga, Y., Cohen, S., Meron, M., Bosak, A., Tsipris, J., Ostrovsky, V., Orolov, V., Levi, A., Brikman, R.: Crop water status estimation using thermography: multi-year model development using ground-based thermal images, *Precision Agriculture*, 2014.
- [8] Grant, O. M., Ochagavía, H., Baluja, J., Diago, M. P., Tardáguila, J.: Thermal imaging to detect spatial and temporal variation in the water status of grapevine (*Vitis vinifera* L.), *The Journal of Horticultural Science and Biotechnology*, 2016.
- [9] O'Shaughnessy, S. A., Evett, S. R., Colaizzi, P. D., Howell, T. A.: Using radiation thermography and thermometry to evaluate crop water stress in soybean and cotton, *Agricultural Water Management*, 2011.
- [10] Benšić, M., Šuvak, N.: Statistika – radni materijali, Sveučilište J.J. Strossmayera u Osijeku, 2010.
- [11] Oskabe, Y., Oskabe, K., Shinozaki, K., Tran, L.S.P.: Response of plants to water stress, *Frontiers in Plant Science*, 2014.

-
- [12] Bray, E. A.: Plant Response to water-deficit stress, Encyclopedia of Life Sciences, 2001.
- [13] Zhu, X.C., Song, F.B., Liu, S.Q., Liu, T.D., Zhou, X.: Arbuscular mycorrhizae improves photosynthesis and water status of *Zea mays* L. Under drought stress, Plant Soil Environ, 2012.
- [14] http://www.italpollina.com/en/product/37/AEGIS_MICROGRANULE

PRILOZI

I. CD-R disc